

应用随机过程

林元烈 编著

清华大学数学科学系

2001 年 8 月

序 言

《应用随机过程》一书是作者多年来累积该学科的教学与研究的经验后编著而成的一本研究生教材。

本教材力求强调以下诸点：

1. 着眼于引发兴趣，使读者领悟其思想，感受其魅力与威力。
2. 着重于揭示概念的来源及背景，典型随机模型的提炼、特性刻画和它们的应用以及发展的踪迹。
3. 主要用概率的观点与方法研究与领略若干最基本的但至今仍有旺气与潜力的随机过程的主要特征与风采。
4. 将条件数学期望作为现代随机过程的最基本的概念之一，并力求用初等的便于直观确切理解的方法描述它的定义与重要性质。由于现代随机过程及其应用领域常常更关心的是许多不同时刻随机变量之间的各种关系，而条件数学期望是刻画不同随机变量之间各种关系的最佳工具。因此随着现代科技的迅猛发展，条件数学期望将在其中发挥愈来愈重要的作用。本教材力求对这种发展趋势予以及时的反映。
5. 对若干发展特别迅速，应用愈来愈广泛的分支，如鞅，Brown 运动与 Itô 随机积分，及点过程等予以初步的介绍。
6. 突出全概率公式（及其推广与各种变形）中所蕴含的基本思想与技巧，把它作为贯穿本教材的主导线索之一，并加以阐明和应用。
7. 反映了若干新成果，可以作为教学与科研相结合的切入点。

本书是应用随机过程的入门教材，仅以初等概率论及高等数学、线性代数作为基础，适用于重点大学研究生及高班本科生的必修课，亦可作为一般院校研究生，本科生以及工程管理人员的参考书。

限于作者水平，错误在所难免。敬请指正。

作 者

2001.2.

目录

第一章 预备知识与随机过程的基本概念	1
§ 1.1 概率	1
§ 1.2 随机变量、分布函数及数字特征	4
§ 1.3 矩母函数、特征函数和拉氏变换	11
§ 1.4 条件数学期望	13
§ 1.5 随机过程的概念	21
§ 1.6 随机过程的分类	24
练习题	26
第二章 Poisson 过程及其推广	30
§ 2.1 定义与背景	30
§ 2.2 相邻事件的时间间隔, Poisson 过程与指数分布的关系	32
§ 2.3 剩余寿命与年龄	36
§ 2.4 到达时间的条件分布	39
§ 2.5 Poisson 过程的模拟、检验及参数估计	44
§ 2.6 非时齐 Poisson 过程	46
§ 2.7 复合 Poisson 过程	47
§ 2.8 条件 Poisson 过程	48
§ 2.9 更新过程	49
§ 2.10 若干极限定理与基本更新过程	50
§ 2.11 更新方程与关键更新定理	55
练习题	62
第三章 马尔可夫链	65
§ 3.1 定义与例子	65
§ 3.2 转移概率矩阵	69
§ 3.3 状态的分类	71
§ 3.4 状态空间的分解	87
§ 3.5 P^n 的极限性态与平稳分布	90
§ 3.6 离散时间的 Phase - Type 分布	97

§ 3.7 首达目标模型与其它模型的关系	98
练习题	103
第四章 离散鞅引论	109
§ 4.1 定义与例子	109
§ 4.2 上鞅(下鞅)及分解定理	115
§ 4.3 停时与停时定理	120
§ 4.4 鞅收敛定理	131
§ 4.5 连续参数鞅	136
练习题	137
第五章 Brown 运动	141
§ 5.1 随机游动与 Brown 运动的定义	141
§ 5.2 Brown 运动轨道的性质	148
§ 5.3 首中时与最大值	152
§ 5.4 Brown 桥	156
§ 5.5 Brown 运动的各种变形与推广	159
§ 5.6 带有漂移的 Brown 运动	163
§ 5.7 n 维 Brown 运动与牛顿位势	171
§ 5.8 用 Monte Carlo 方程求解 Laplace 方程	179
练习题	180
第六章 连续参数马氏链	183
§ 6.1 转移率矩阵— Q 矩阵及其概率意义	184
§ 6.2 Kolmogorov 向前向后微分方程	189
§ 6.3 生灭过程	197
§ 6.4 强马氏性与嵌入马氏链	203
§ 6.5 连续参数马氏链的模拟	210
§ 6.6 可逆马氏链	212
§ 6.7 马氏更新过程与半马氏过程	216
§ 6.8 连续时间马氏链与离散时间马氏链首达目标模型的关系	220
§ 6.9 首达时间与首达目标积分型泛函的特性及其反问题	224

§ 6.10 状态分类	230
练习题	232
第七章 随机微分方程	237
§ 7.1 H 空间和均方收敛	237
§ 7.2 均方分析	240
§ 7.3 伊藤 (Itô) 随机积分	245
§ 7.4 Itô 随机过程和 Itô 公式	248
§ 7.5 (Itô) 随机微分方程 (Itô Stochastic Differentiated Equations)	252
§ 7.6 解的存在和唯一性问题	257
§ 7.7 解的基本特性与扩散过程	258
练习题	261
第八章 宽平稳过程	265
§ 8.1 宽平稳过程的定义和举例	265
§ 8.2 正态过程	267
§ 8.3 ARMA 过程	273
§ 8.4 平稳过程的谱分解和协方差函数 (相关函数) 的谱分解	279
§ 8.5 最佳均方预测与最佳线性均方预测	285
§ 8.6 各态历经性	289
§ 8.7 线性系统中的平稳过程	293
练习题	298
参考文献	301

第一章 预备知识与随机过程的基本概念

§ 1.1 概率

概率论的一个基本概念是随机试验. 一个试验 (或观察), 若它的结果预先无法确定, 则称之为 **随机试验**, 简称为 **试验** (experiment). 所有试验的可能结果组成的集合, 称为 **样本空间**, 记作 Ω . Ω 中的元素则称为 **样本点**, 用 ω 表示. 由 Ω 的某些样本点构成的子集合, 常用大写字母 A, B, C 等表示, 由 Ω 中的若干子集构成的集合称为 **集类**, 用花写字母 $\mathcal{A}, \mathcal{B}, \mathcal{F}$ 等表示.

由于并不是在所有的 Ω 的子集上都能方便地定义概率, 一般我们只限制在满足一定条件的集类上研究概率性质, 为此我们引入 σ 域的概念:

定义 设 \mathcal{F} 为由 Ω 的某些子集构成的非空集类, 若满足:

1° $\Omega \in \mathcal{F}$;

2° 若 $A \in \mathcal{F}$, 则 $A^C \in \mathcal{F}$, A^C 是 A 的补集, 即 $A^C = \bar{A} = \Omega - A$;

3° 若 $A_n \in \mathcal{F}, n \in N$, 则 $\bigcup_{n=1}^{\infty} A_n \in \mathcal{F}$.

则称 \mathcal{F} 为 σ 域 (σ 代数). 称 (Ω, \mathcal{F}) 为 **可测空间**. □

容易验证, 若 \mathcal{F} 为 σ 域, 则 \mathcal{F} 对可列次交、并、差等运算封闭, 即 \mathcal{F} 中的任何元素经可列次运算后仍属于 \mathcal{F} . 例: 集类 $\mathcal{F}_0 = \{\emptyset, \Omega\}$, $\mathcal{F}_1 = \{\emptyset, A, A^C, \Omega\}$ 及 $\mathcal{F}_2 = \{A: \forall A \subset \Omega\}$ 均是 σ 域, 但集类 $\mathcal{A} = \{\emptyset, A, \Omega\}$ 不是 σ 域.

通常我们最关心的是包含我们所要研究对象的最小 σ 域. 设 \mathcal{A} 为由 Ω 的某些子集构成的集类, 一切包含 \mathcal{A} 的 σ 域的交, 记为 $\sigma(\mathcal{A})$. 称 $\sigma(\mathcal{A})$ 为由 \mathcal{A} 生成的 σ 域, 或称为包含 \mathcal{A} 的最小 σ 域. 例: $\mathcal{A} = \{\emptyset, A, \Omega\}$, 则 $\sigma(\mathcal{A}) = \{\emptyset, A, A^C, \Omega\}$. 一维 Borel σ 域: 包含 \mathbb{R} 上所有形如集合 $(-\infty, a]$ 的最小 σ 域称为一维 Borel σ 域, 记为 \mathcal{B} , 即 $\mathcal{B} = \sigma((-\infty, a], \forall a \in \mathbb{R})$.

定义 设 (Ω, \mathcal{F}) 为可测空间, P 是一个定义在 \mathcal{F} 上的集函数, 若满足:

1° $P(A) \geq 0, \forall A \in \mathcal{F}$; (非负性)

2° $P(\Omega) = 1$; (归一性)

3° 若 $A_i \in \mathcal{F}, i = 1, 2, \dots$, 且 $A_i A_j = \emptyset, \forall i \neq j$, 有

$$P\left(\bigcup_{i=1}^{\infty} A_i\right) = \sum_{i=1}^{\infty} P(A_i). \quad (\text{可列可加性})$$

则称 P 为可测空间 (Ω, \mathcal{F}) 上的一个 **概率测度** (Probability measure), 简称 **概率** (Probability). 称 (Ω, \mathcal{F}, P) 为 **概率空间** (Probability space), 称 \mathcal{F} 为事件域. 若 $A \in \mathcal{F}$, 则称 A 为 **随机事件** (random event), 简称为 **事件**, 称 $P(A)$ 为事件 A 的概率.

事件的概率刻画了事件出现可能性的大小. 概率的基本性质如下:

1° 若 $A \subset B$, 则 $P(A) \leq P(B)$.

2° $P(A^C) = 1 - P(A)$.

3° 若 A_1, A_2, \dots, A_n 互不相容, 则

$$P\left(\bigcup_{i=1}^n A_i\right) = \sum_{i=1}^n P(A_i). \quad (\text{有限可加性})$$

4° 对任意二个事件 A 及 B , 有

$$P(A \cup B) = P(A) + P(B) - P(AB),$$

$$P(A - B) = P(A) - P(AB).$$

5° 对任意 A_1, A_2, \dots, A_n 有

$$\begin{aligned} P\left(\bigcup_{i=1}^n A_i\right) &= \sum_{i=1}^n P(A_i) - \sum_{i < j \leq n} P(A_i A_j) + \sum_{i < j < k \leq n} P(A_i A_j A_k) \\ &\quad - \dots + (-1)^{n+1} P(A_1 A_2 \dots A_n). \\ P\left(\bigcup_{i=1}^n A_i\right) &\leq \sum_{i=1}^n P(A_i). \end{aligned}$$

例: 1. $[0, 1]$ 上的 Borel 概率空间. 设 $\Omega = [0, 1], \mathcal{F} = \mathcal{B}[0, 1]$, 即 $\mathcal{B}[0, 1]$ 是 \mathcal{B} 局限在 $[0, 1]$ 上的 Borel σ -域. 称 $(\Omega, \mathcal{F}) = ([0, 1], \mathcal{B}[0, 1])$ 为 $[0, 1]$ 上的 Borel 可测空间. 设在可测空间 $([0, 1], \mathcal{B}[0, 1])$ 上定义一概率测度 P , 它满足: 当 $\forall A = [a, b] \in \mathcal{B}[0, 1]$ 时, $P(A) = b - a$, 称 $(\Omega, \mathcal{F}, P) = ([0, 1], \mathcal{B}[0, 1], P)$ 为 $[0, 1]$ 上的 Borel 概率空间, 称 P 为 $[0, 1]$ 上的 Borel 概率测度.

2. 令 $B = [0, 1]$ 上有理点全体, $\bar{B} = [0, 1]$ 上无理点全体.

(1) 试证: $B \in \mathcal{F}, \bar{B} \in \mathcal{F}$;

(2) 用公理化定义与性质, 求证: $P(B) = 0, P(\bar{B}) = 1$.

证明: $\forall a \in [0, 1]$, 单点集 $a = \bigcap_{n=1}^{\infty} [a, a + \frac{1}{n}) \in \mathcal{B}[0, 1] = \mathcal{F}$, 而 $B = 0 \cup \{\frac{m}{n} : 1 \leq m \leq n, n, m = \{1, 2, \dots\}\}$ 是可列单点集的并, 故 $B \in \mathcal{F}$. 且 $\bar{B} = [0, 1] - B \in \mathcal{F}$. 又 $\forall a \in [0, 1], P(a) = 0$, 由完全可加性知 $P(B) = 0$, 而 $\bar{B} = [0, 1] - B$, 故 $P(\bar{B}) = 1 - 0 = 1$. 证毕.

概率的一个重要性质是它具有连续性. 为此先引入事件列的极限.

一事件列 $\{A_n, n \geq 1\}$ 称为单调 **增序列**, 若 $A_n \subset A_{n+1}, n \geq 1$; 称为单调 **减序列**, 若 $A_n \supset A_{n+1}, n \geq 1$. 如果 $\{A_n, n \geq 1\}$ 是单调增序列, 定义 $\lim_{n \rightarrow \infty} A_n = \bigcup_{i=1}^{\infty} A_i$. 如果 $\{A_n, n \geq 1\}$ 是单调减序列, 定义 $\lim_{n \rightarrow \infty} A_n = \bigcap_{i=1}^{\infty} A_i$.

连续性定理如下:

1.1 概率

命题 1.1.1 若 $\{A_n, n \geq 1\}$ 是单调增序列 (或减序列), 则

$$\lim_{n \rightarrow \infty} P(A_n) = P(\lim_{n \rightarrow \infty} A_n).$$

证: 先设 $\{A_n, n \geq 1\}$ 为单调增序列, 令

$$B_1 = A_1, B_n = A_n \left(\bigcup_{i=1}^{n-1} A_i \right)^C = A_n A_{n-1}^C, \quad n > 1.$$

容易验证 $\{B_n, n \geq 1\}$ 互不相容. 且有 $\bigcup_{i=1}^n A_i = \bigcup_{i=1}^n B_i, n \geq 1$ 及 $\bigcup_{i=1}^{\infty} A_i = \bigcup_{i=1}^{\infty} B_i$, 故

$$\begin{aligned} P(\lim_{n \rightarrow \infty} A_n) &= P\left(\bigcup_{i=1}^{\infty} A_i\right) = P\left(\bigcup_{i=1}^{\infty} B_i\right) = \sum_{i=1}^{\infty} P(B_i) && (\text{公理 3}^\circ) \\ &= \lim_{n \rightarrow \infty} \sum_{i=1}^n P(B_i) = \lim_{n \rightarrow \infty} P\left(\bigcup_{i=1}^n B_i\right) \\ &= \lim_{n \rightarrow \infty} P\left(\bigcup_{i=1}^n A_i\right) = \lim_{n \rightarrow \infty} P(A_n). && (A_n = \bigcup_{i=1}^n A_i) \end{aligned}$$

若 $\{A_n, n \geq 1\}$ 为单调减序列, 则 $\{A_n^C, n \geq 1\}$ 为单调增序列, 于是

$$P\left(\bigcup_{n=1}^{\infty} A_n^C\right) = \lim_{n \rightarrow \infty} P(A_n^C),$$

由

$$\bigcup_{n=1}^{\infty} A_n^C = \left(\bigcap_{n=1}^{\infty} A_n\right)^C,$$

有

$$1 - P\left(\bigcap_{n=1}^{\infty} A_n\right) = \lim_{n \rightarrow \infty} (1 - P(A_n)),$$

即

$$P\left(\bigcap_{n=1}^{\infty} A_n\right) = \lim_{n \rightarrow \infty} P(A_n). \quad \square$$

下面是著名的 Borel-Cantelli 引理.

命题 1.1.2 设 $\{A_n, n \geq 1\}$ 是一事件序列, 若 $\sum_{i=1}^{\infty} P(A_i) < \infty$, 则

$$P(\limsup_{i \rightarrow \infty} A_i) = 0.$$

其中 $\limsup_{i \rightarrow \infty} A_i \triangleq \bigcap_{n=1}^{\infty} \bigcup_{i=n}^{\infty} A_i$.

证: 易知 $\bigcup_{i=n}^{\infty} A_i$ 是关于 n 的单调减序列, 故由命题 1.1.1 有

$$\begin{aligned} 0 &\leq P\left(\bigcap_{n=1}^{\infty} \bigcup_{i=n}^{\infty} A_i\right) = P\left(\lim_{n \rightarrow \infty} \bigcup_{i=n}^{\infty} A_i\right) \\ &= \lim_{n \rightarrow \infty} P\left(\bigcup_{i=n}^{\infty} A_i\right) \stackrel{3}{\leq} \lim_{n \rightarrow \infty} \sum_{i=n}^{\infty} P(A_i) = 0. \quad \square \end{aligned}$$

命题 1.1.3 若 $\{A_n, n \geq 1\}$ 是相互独立的事件序列, 且有 $\sum_{n=1}^{\infty} P(A_n) = \infty$, 则有

$$P\left(\bigcap_{n=1}^{\infty} \bigcup_{i=n}^{\infty} A_i\right) = 1.$$

证:

$$P\left(\bigcap_{n=1}^{\infty} \bigcup_{i=n}^{\infty} A_i\right) = P\left(\lim_{n \rightarrow \infty} \bigcup_{i=n}^{\infty} A_i\right) = \lim_{n \rightarrow \infty} P\left(\bigcup_{i=n}^{\infty} A_i\right) = \lim_{n \rightarrow \infty} [1 - P\left(\bigcap_{i=n}^{\infty} A_i^C\right)].$$

但

$$\begin{aligned} P\left(\bigcap_{i=n}^{\infty} A_i^C\right) &= \prod_{i=n}^{\infty} P(A_i^C) && \text{(由独立性)} \\ &= \prod_{i=n}^{\infty} (1 - P(A_i)) \leq \prod_{i=n}^{\infty} e^{-P(A_i)} && \text{(由 } 1 - x \leq e^{-x}, x \geq 0 \text{)} \\ &= \exp\left(-\sum_{i=n}^{\infty} P(A_i)\right) = 0. && \text{(因为 } \sum_{i=n}^{\infty} P(A_i) = \infty \text{ 对所有 } n \text{)} \end{aligned}$$

因此命题得证. □

§ 1.2 随机变量、分布函数及数字特征

1. 随机变量与分布函数

考虑一样本空间 Ω , 记 \mathbb{R} 为实数全体所成之集. 随机变量定义为:

定义 设 (Ω, \mathcal{F}, P) 是一概率空间, $X(\omega)$ 是定义在 Ω 上的单值实函数, 如果对 $\forall a \in \mathbb{R}$, 有 $\{\omega : X(\omega) \leq a\} \in \mathcal{F}$, 则称 $X(\omega)$ 为 **随机变量**(random variable). □

这里有点说明, 1) $\{\omega : X(\omega) \leq a\}$ 是指所有满足 $X(\omega) \leq a$ 的样本点 ω 的集合. 定义要求 $\{\omega : X(\omega) \leq a\}$ 是 (Ω, \mathcal{F}, P) 的一个事件, 因而可定义它的概率. 2) 定义中 ω 为自变量, 为了书写方便, 简记 $\{\omega : X(\omega) \leq a\} = \{X \leq a\} = \{X \in (-\infty, a]\}$. 以下把 $X(\omega)$ 记为 X . 一般随机变量符号用大写字母 X, Y, Z 等表示. 3) $X(\omega)$ 满足 $\{\omega : X(\omega) \leq a\} \in \mathcal{F}$, 则易证: $\forall a, b \in \mathbb{R}, \{X > a\}, \{X < a\}, \{X = a\}, \{a < X \leq b\}, \{a \leq X < b\}, \{a < X < b\}, \{a \leq X \leq b\} \in \mathcal{F}$.

例 1 若 (Ω, \mathcal{F}) 中的 $\mathcal{F} = \{\emptyset, A, A^C, \Omega\}$, $A \in \mathcal{F}$ 而 $A_1 \notin \mathcal{F}$, 容易验证 A_1 的示性函数 $I_{A_1}(\omega)$ 使 $(I_{A_1} \leq \frac{1}{2}) \notin \mathcal{F}$. 故 $I_{A_1}(\omega)$ 对 \mathcal{F} 而言不满足随机变量的定义.

例 2 给定 (Ω, \mathcal{F}) , 设 $\{B_k\} (0 \leq k < \infty)$ 是 Ω 的一个划分, 即 $B_k B_l = \emptyset (k \neq l); \bigcup_{k=1}^{\infty} B_k = \Omega$ 且 $B_k \in \mathcal{F}, 0 \leq k < \infty$, 定义 $X(\omega) = \sum_{k=1}^{\infty} x_k I_{B_k}(\omega)$, 则容易验证 $X(\omega)$ 是随机变量.

1.2 随机变量、分布函数及数字特征

可以证明, $\forall B \in \mathcal{B}, \{\omega, X(\omega) \in B\} \in \mathcal{F}$, 等价于 $\forall a \in \mathbb{R}, \{\omega, X(\omega) \leq a\} \in \mathcal{F}$. 参见 [21,22]. 简记 $X = X(\omega)$, 且记 $X^{-1}(B) = (\omega : X(\omega) \in B)$. 随机变量简记为 r.v..

设 X 为 (Ω, \mathcal{F}, P) 上的随机变量, 对 $\forall x \in \mathbb{R}$,

$$F(x) = P(X \leq x) = P(X \in (-\infty, x]),$$

称 $F(x)$ 为 X 的 **分布函数**(distribution function).

若随机变量 X 的可能取值的全体是一可数集或有限集, 则称 X 是离散型随机变量, 简记为 d.r.v..

对 r.v. X 的分布函数 $F(x)$, 若存在一非负函数 $f(x)$, 对 $\forall x \in \mathbb{R}$, 有

$$F(x) = \int_{-\infty}^x f(u) du,$$

则称 $f(x)$ 为 r.v. X 的 **概率密度函数**(probability density function, 简记为 p.d.f.). 若 $f(x)$ 在 x 连续, 则 $\frac{dF(x)}{dx} = f(x)$, 即

$$\lim_{h \rightarrow 0} \frac{P(x < X \leq x+h)}{h} = f(x),$$

或

$$P(x < X \leq x+h) = f(x)h + o(h).$$

以上关系是以后用所谓“微元法”求 p.d.f. 的依据: 为求 r.v. X 的 p.d.f., 先求 X 落在一个小区间 $(x, x+h]$ 上的概率 $P(x < X \leq x+h)$, 然后让 $h \rightarrow 0$, 求其极限 $\lim_{h \rightarrow 0} P(x < X \leq x+h)/h$, 即得 $f(x)$.

二维随机变量 (X, Y) 的 **联合分布** $F(x, y)$ 定义为

$$F(x, y) = P(X \leq x, Y \leq y).$$

X 和 Y 的 **边缘分布** 为

$$F_X(x) = P(X \leq x) = \lim_{y \rightarrow +\infty} F(x, y) = F(x, +\infty),$$

$$F_Y(y) = P(Y \leq y) = \lim_{x \rightarrow +\infty} F(x, y) = F(+\infty, y).$$

若存在一非负函数 $f(x, y)$, 对 $\forall (x, y) \in \mathbb{R}^2$ 有

$$F(x, y) = \int_{-\infty}^x \int_{-\infty}^y f(u, v) du dv,$$

则称 $f(x, y)$ 为 (X, Y) 的 **联合概率密度函数**. (简记 j.p.d.f.).

称随机变量 X 与 Y **相互独立**, 若对 $\forall (x, y) \in \mathbb{R}^2$, 有

$$F(x, y) = F_X(x)F_Y(y).$$

n 维随机向量 X_1, X_2, \dots, X_n 的 **联合分布函数**(joint distribution function) 定义为

$$F(x_1, x_2, \dots, x_n) = P(X_1 \leq x_1, X_2 \leq x_2, \dots, X_n \leq x_n).$$

若对 $\forall (x_1, x_2, \dots, x_n) \in \mathbb{R}^n$ 有

$$F(x_1, x_2, \dots, x_n) = F_1(x_1)F_2(x_2) \cdots F_n(x_n),$$

则称 X_1, X_2, \dots, X_n 相互独立 (independent). 这里

$$F_i(x_i) = \lim_{x_j \rightarrow \infty, j \neq i} F(x_1, x_2, \dots, x_i, \dots, x_n) = P(X_i \leq x_i).$$

2. Riemann—Stieltjes 积分

为以后表示简便, 这里我们引出 Riemann—Stieltjes 积分.

设 $F(x)$ 为 $(-\infty, +\infty)$ 上的单调不减右连续函数, $g(x)$ 为 $(-\infty, +\infty)$ 上的单值实函数, $\forall a < b$.

定义 任取分点 $a = x_0 < x_1 < x_2 < \cdots < x_{i-1} < x_i \cdots < x_n = b, \forall u_i \in [x_{i-1}, x_i]$, 作积分和式

$$\sum_{i=1}^n g(u_i) \Delta F(x_i) = \sum_{i=1}^n g(u_i) [F(x_i) - F(x_{i-1})]$$

令 $\lambda = \max_{1 \leq i \leq n} \Delta x_i = \max_{1 \leq i \leq n} (x_i - x_{i-1})$, 若极限

$$J(a, b) = \lim_{\lambda \rightarrow 0} \sum_{i=1}^n g(u_i) \Delta F(x_i)$$

存在, 则记

$$J(a, b) = \int_a^b g(x) dF(x) \quad \left(\text{或} \int_a^b g(x) F(dx) \right),$$

称极限 $J(a, b)$ 为 $g(x)$ 关于 $F(x)$ 在 $[a, b]$ 上的 R-S 积分. □

注: (1) $\lambda \rightarrow 0$ 意味着 $n \rightarrow \infty$, 且最大子区间长度趋于 0. (2) 当取 $F(x) = x$ 时, R-S 积分化为原来的 Riemann 积分, 所以 R-S 积分是 Riemann 积分的推广.

当 $a \rightarrow -\infty, b \rightarrow +\infty$ 时, 若极限

$$J(-\infty, +\infty) = \lim_{b \rightarrow \infty, a \rightarrow -\infty} \int_a^b g(x) dF(x)$$

存在, 则称

$$J(-\infty, +\infty) = \int_{-\infty}^{+\infty} g(x) dF(x) \quad \text{或} \quad \int_{-\infty}^{+\infty} g(x) F(dx)$$

为 $g(x)$ 关于 $F(x)$ 在 $(-\infty, +\infty)$ 上的 R-S 积分.

1.2 随机变量、分布函数及数字特征

R-S 积分的基本性质:

1° 在 $a < c_1 < \cdots < c_n < b$ 时

$$\int_a^b g(x) dF(x) = \sum_{i=0}^n \int_{c_i}^{c_{i+1}} g(x) dF(x), \quad (a = c_0, b = c_{n+1});$$

2°

$$\int_a^b \sum_{i=1}^n g_i(x) dF(x) = \sum_{i=1}^n \int_a^b g_i(x) dF(x);$$

3° 若 $g(x) \geq 0$, 且 $a < b$, 则

$$\int_a^b g(x) dF(x) \geq 0;$$

4° 若 $F_1(x), F_2(x)$ 为二分布函数, C_1, C_2 为常数. $C_1, C_2 > 0$, 则

$$\int_a^b g(x) d[C_1 F_1(x) + C_2 F_2(x)] = C_1 \int_a^b g(x) dF_1(x) + C_2 \int_a^b g(x) dF_2(x).$$

几个特例:

设 $F(x)$ 为 X 的分布函数.

1° 若 $g(x) = 1$, 则

$$\int_a^b dF(x) = F(b) - F(a) = P(a < X \leq b).$$

2° 若 X 为离散型随机变量, 即 $P(X = c_i) = p_i, i \in N = \{1, 2, \cdots\}$ 则

$$F(x) = \sum_{c_i \leq x} p_i$$

是一跳跃型分布函数, 即 $F(x)$ 的变化只在 c_1, c_2, \cdots , 这些点且其跃度为 p_i , 则 R-S 积分

$$\int_{-\infty}^{\infty} g(x) dF(x) = \sum_{n=1}^{\infty} g(c_n) [F(c_n + 0) - F(c_n - 0)] = \sum_{n=1}^{\infty} g(c_n) p_n$$

化成了一个级数.

3. 数字特征

(1). 随机变量的数学期望 (Expectation or Mean)

定义 设 X 为 r.v., $F(x)$ 为 d.f., 若 $\int_{-\infty}^{+\infty} |x| dF(x)$ 存在, 则称

$$EX = \int_{-\infty}^{\infty} x dF(x)$$

为 r.v. X 的 **数学期望**(或称为 X 的均值). □

性质 1° 若 $(C_i, i = 1, 2, \dots, n)$ 为常数, $(X_i, i = 1, 2, \dots, n)$ 为 r.v., 则

$$E\left(\sum_{i=1}^n C_i X_i\right) = \sum_{i=1}^n C_i E X_i.$$

性质 2° 设 $g(x)$ 为 x 的函数, $F_X(x)$ 为 X 的分布函数, 若 $E[g(X)]$ 存在, 则

$$E[g(X)] = \int_{-\infty}^{\infty} g(x) dF_X(x).$$

当 X 为 d.r.v. 时, 即 $P(X = x_n) = p_n, n \in N$, 则

$$EX = \sum_{n=1}^{\infty} x_n p_n$$

即 EX 是 X 所有可能取值的加权平均.

当 X 为连续型 r.v. 时, 简记为 c.r.v., 且有 p.d.f. $f(x)$, 则

$$EX = \int_{-\infty}^{+\infty} x f(x) dx.$$

(2). 方差 (Variance)

定义 令 $DX \triangleq E(X - EX)^2 = EX^2 - (EX)^2$, 称 DX 为 r.v. X 的 **方差**(有时记 $DX = \text{Var } X = \sigma_X^2$). □

DX 刻画了 X 取值的集中或分散程度.

(3). 协方差 (Covariance)

定义 二个 r.v. (X, Y) , 称

$$\text{Cov}(X, Y) \triangleq E[(X - EX)(Y - EY)] = E(XY) - (EX)(EY)$$

为 (X, Y) 的 **协方差**. □

我们知道, 若 X, Y 独立, 则 $E(XY) = EX EY \Rightarrow \text{Cov}(X, Y) = 0$. 于是, 若 $\text{Cov}(X, Y) \neq 0 \Rightarrow X, Y$ 不独立. 因此 $\text{Cov}(X, Y) \neq 0$ 刻画了 X, Y 取值存在某种统计上的线性相关关系.

(4). 相关系数 (Correlation coefficient)

定义 若 $0 < DX = \sigma_X^2 < \infty, 0 < DY = \sigma_Y^2 < \infty$, 称

$$\rho(X, Y) = \frac{\text{Cov}(X, Y)}{\sigma_X \sigma_Y}$$

1.2 随机变量、分布函数及数字特征

为 (X, Y) 的 **相关系数**.

$\rho(X, Y)$ 刻画了 X, Y 之间线性关系的密切程度, 若 $\rho = 0$ 称 X, Y 不相关.

主要性质:

1°

$$D\left(\sum_{i=1}^n a_i X_i\right) = \sum_{i=1}^n a_i^2 D X_i + 2 \sum_{i < j} a_i a_j \operatorname{Cov}(X_i, X_j);$$

2° 若 X_1, X_2, \dots, X_n 相互独立, 则 $\operatorname{Cov}(X_i, X_j) = 0, \quad j \neq i$, 即 X_i, X_j 不相关;

3° 若 X_1, X_2, \dots, X_n 两两不相关, 则

$$D\left(\sum_{i=1}^n X_i\right) = \sum_{i=1}^n D X_i;$$

4° Schwarz 不等式, 若 r.v. X, Y 的二阶矩存在, 则

$$|E(XY)|^2 \leq E(X^2) \cdot E(Y^2);$$

特别是

$$|\operatorname{Cov}(X, Y)|^2 \leq \sigma_X^2 \cdot \sigma_Y^2,$$

$$|\rho(X, Y)| \leq 1.$$

5° $\rho = \pm 1$, 当且仅当

$$P\left(\frac{Y - EY}{\sqrt{DY}} = \pm \frac{X - EX}{\sqrt{DX}}\right) = 1,$$

即 $\rho = \pm 1$ 时, (X, Y) 以概率 1 取值在直线 $Y - EY = \pm \sqrt{DY}(X - EX)/\sqrt{DX}$ 上.

(5). 矩 (Moment)

定义 记

$$E(X^k) = \int_{-\infty}^{+\infty} x^k dF_X(x), \quad (k \geq 1),$$

称 $E(X^k)$ 为 r.v. X 的 k **阶矩** ($k \in N$).

□

4. 常用随机变量的分布

离散型随机变量 (d.r.v.):

(1). 二项分布

设 $0 \leq p < 1, n \geq 1$, 若 X 的分布律为

$$P(X = k) = C_n^k p^k (1-p)^{n-k}, \quad 0 \leq k \leq n,$$

称 X 是参数为 (n, p) 的二项分布 (Binomial with parameters (n, p)). 简记 $X \sim B(n, p)$.

(2). Poisson 分布

设 $\lambda > 0$, 若 X 的分布律为

$$P(X = k) = \frac{\lambda^k}{k!} e^{-\lambda}, \quad k = 0, 1, 2, \dots,$$

称 X 是参数为 λ 的 Poisson 分布 (Poisson with parameter λ). 简记 $X \sim P(\lambda)$.

(3). 几何分布

设 $0 < p < 1$, 若 X 的分布律为

$$P(X = k) = (1-p)^{k-1} p, \quad k = 1, 2, \dots,$$

称 X 是参数为 p 的几何分布 (Geometric distribution). 简记 $X \sim G(p)$.

具有概率密度的随机变量:

(4). 均匀分布

设 $a < b$, 若 X 的 p.d.f. 为

$$f(x) = \begin{cases} \frac{1}{b-a} & a < x < b, \\ 0 & \text{其它.} \end{cases}$$

称 X 是 (a, b) 上的均匀分布 (Uniform over (a, b)). 简记 $X \sim U(a, b)$.

(5). 正态分布

设 $\mu \in \mathbb{R}, \sigma > 0$, 若 X 的 p.d.f. 为

$$f(x) = \frac{1}{\sqrt{2\pi}\sigma} \exp\{-(x-\mu)^2/2\sigma^2\},$$

称 X 是参数为 (μ, σ^2) 的正态分布 (normal with parameters (μ, σ^2)). 简记 $X \sim N(\mu, \sigma^2)$.

(6). 指数分布

1.3 矩母函数、特征函数和拉氏变换

设 $\lambda > 0$, 若 X 的 p.d.f. 为

$$f(x) = \begin{cases} \lambda e^{-\lambda x} & x \geq 0, \\ 0 & x < 0. \end{cases}$$

称 X 是参数为 λ 的指数分布 (Exponential with parameter λ). 简记 $X \sim E(\lambda)$.

5. 连续型随机变量的事件示性函数的线性组合表示

(1). 设 $X(\omega)$ 为非负随机变量, $P(X < \infty) = 1$, 令

$$X_n(\omega) = \sum_{k=0}^{n2^n-1} \frac{k}{2^n} I\{\frac{k}{2^n} \leq X < \frac{k+1}{2^n}\}(\omega) + nI\{X \geq n\}(\omega)$$

则 $X_n(\omega)$ 是随机变量, 且 $|X_n(\omega) - X(\omega)| < \frac{1}{2^n}$ 当 $0 \leq X(\omega) < n$ 时, $X_n(\omega) = n$ 当 $X(\omega) = n$ 时, 故 $\lim_{n \rightarrow \infty} X_n(\omega) = X(\omega)$.

(2). 设 $X(\omega)$ 为一般随机变量, 令 $X^+ = (X \vee 0)$, $X^- = -(X \wedge 0)$, 显然 $X^+, X^- \geq 0$ 由上, 对 X^+, X^- 存在 $X_n^+ \nearrow X^+, X_n^- \nearrow X^-$ 令 $X_n = X_n^+ - X_n^-$, 则 $X_n \nearrow X$.

§ 1.3 矩母函数、特征函数和拉氏变换

1. 矩母函数 (Moment generating function)

定义 r.v. X 的 **矩母函数** 定义为

$$\psi(t) \triangleq E(e^{tX}) = \int_{-\infty}^{+\infty} e^{tx} dF_X(x),$$

如上式右边积分存在.

□

显然, 如 X 的 k 阶矩存在, 则

$$E(X^k) = \psi^{(k)}(0).$$

矩母 (生成) 函数由此得名. 可以证明矩母函数与分布函数是一一对应的.

对于取值非负整数 r.v. X , 即 $P(X = k) = p_k \geq 0 (k \geq 0)$, $\sum_{k=0}^{\infty} p_k = 1$, 则 X 的矩母函数记为

$$g(s) = E(s^X) = \sum_{k=0}^{\infty} p_k s^k, \quad 0 \leq s \leq 1.$$

显然, $p_k = g^{(k)}(0)/k!$, 且有 $E[X(X-1)(X-2)\cdots(X-k-1)] = g^{(k)}(1)$. 若 X_1, X_2 相互独立, 矩母函数记为 $g_1(s), g_2(s)$. 则不难证明 $X_1 + X_2$ 的矩母函数为

$$g_{X_1+X_2}(s) = g_1(s)g_2(s).$$

对于数列 $\{a_n, n \geq 0\}$, 如

$$A(s) = \sum_{n=0}^{\infty} a_n s^n, \quad |s| \leq 1,$$

则称 $A(s)$ 为 $\{a_n, n \geq 0\}$ 的 **母函数**.

母函数的几个重要性质:

- 1° $E(x) = g'(1)$.
- 2° $D(x) = g''(1) + g'(x) - [g'(1)]^2$.
- 3° $g'(1) = \sum_{k=1}^{\infty} k p_k$.

2. 特征函数 (Characteristic function)

定义 记

$$\phi(t) \triangleq E\{\exp(itX)\} = \int_{-\infty}^{+\infty} \exp(itx) dF_X(x),$$

其中 $i = \sqrt{-1}, -\infty < t < +\infty$. 称 $\phi(t)$ 是 r.v. X 的 **特征函数**. □

$\phi(t)$ 的几个重要性质:

- 1° $\phi(0) = 1, |\phi(t)| \leq \phi(0), \phi(-t) = \overline{\phi(t)}$, 且 $\phi(t)$ 在 $(-\infty, +\infty)$ 上一致连续.
- 2° $\phi(t)$ 具有非负定性, 即对任给 n 个实数 t_i 及复数 $\lambda_i (1 \leq i \leq n)$,

$$\sum_{j=1}^n \sum_{i=1}^n \phi(t_i - t_j) \lambda_i \overline{\lambda_j} \geq 0.$$

- 3° 若 X 与 Y 相互独立, 则

$$\phi_{X+Y}(t) = \phi_X(t) \cdot \phi_Y(t).$$

- 4° r.v. X 若 EX^n 存在, 则当 $k \leq n$ 时

$$\phi^{(k)}(0) = i^k E(X^k).$$

5° r.v. 的分布函数与特征函数是一一对应的关系, 即给定 $F(x)$ 可唯一决定 $\phi(t)$; 反之, 给定 $\phi(t)$ 可唯一决定 $F(x)$ (唯一性定理).

上述性质的证明详见复旦大学编《概率论》第一册.

3. 拉氏变换 (Laplace-Stieltjes transform 简记 L-S 变换)

1.4 条件数学期望

定义 设非负 r.v. X , 分布函数 $F_X(x)$, $s = a + bi$, 这里 $a > 0, b$ 是实数, $i = \sqrt{-1}$. 称

$$\hat{F}_X(s) = \int_0^{+\infty} \exp(-sx) dF_X(x)$$

为 $F_X(x)$ 的 L-S 变换, 或称 r.v. X 的 L-S 变换. □

注意: $\hat{F}_X(s)$ 与 $F_X(x)$ 也是一一对应关系, 且对 $X_1, X_2 \geq 0$ 相互独立, 有

$$\hat{F}_{X_1+X_2}(s) = \hat{F}_{X_1}(s) \cdot \hat{F}_{X_2}(s).$$

§ 1.4 条件数学期望

条件数学期望是随机过程中最基本最重要的概念之一. 为了直观地对此概念有个正确的理解. 我们先从离散型 r.v. (简记 d.r.v.) 入手, 再讨论连续型 r.v. (简记 c.r.v.) 情形, 然后推广到多元 r.v. 的情形.

1. 离散型 r.v. 的情形

设二随机事件 A, B . 若 $P(B) > 0$, 称 $P(A|B) = P(AB)/P(B)$ 为事件 B 发生时, 事件 A 的 **条件概率** (若 $P(B) = 0$, 则 $P(A|B)$ 没定义或规定为 0). 设 (X, Y) 为二个 d.r.v., 其联合分布律为 $P(X = x_i, Y = y_j) = p_{ij} \geq 0, \sum_i \sum_j p_{ij} = 1$, 若 $P(Y = y_j) = \sum_i p_{ij} \triangleq p_{\cdot j} > 0$, 称

$$P(X = x_i | Y = y_j) = P(X = x_i, Y = y_j) / P(Y = y_j) = p_{ij} / p_{\cdot j}$$

为给定 $Y = y_j$ 时, X 的 **条件分布律**. 称

$$E(X | Y = y_j) \triangleq \sum_i x_i P(X = x_i | Y = y_j)$$

为给定 $Y = y_j$ 时, X 的 **条件数学期望**.

比较 (无条件) 数学期望 $EX = \sum_i x_i P(X = x_i)$ 与条件数学期望 $E(X | Y = y_j)$ 的异同: EX 是对所有 $\omega \in \Omega, X(\omega)$ 取值全体的加权平均; 而 $E(X | Y = y_j)$ 是局限在 $\omega \in \{\omega : Y(\omega) = y_j\} \triangleq B_j$ 时, $X(\omega)$ 取值局部 ($\omega \in B_j$) 的加权平均. 这是因为: 记 $B_j = \{\omega : Y = y_j\}, A_i = \{\omega : X = x_i\}$, 于是整个样本空间 Ω 按 Y 的不同取值分为 B_1, \dots, B_j, \dots 各互不相容事件 ($\Omega = \sum_j B_j$). 而 Ω 又按 X 不同取值分为 A_1, \dots, A_i, \dots ($\Omega = \sum_i A_i$) 互不相容事件.

当 $A_i B_j = \emptyset$ 时, $P(X = x_i, Y = y_j) = 0, P(X = x_i | Y = y_j) = 0$, 于是

$$E(X | Y = y_j) = \sum_i x_i P(X = x_i | Y = y_j) = \sum_{i: A_i B_j \neq \emptyset} x_i P(X = x_i | Y = y_j).$$




图 1.4.1

因此 $E(X|Y = y_j)$ 是 $\omega \in B_j$ 时 $X(\omega)$ 的局部加权平均, 如图 1.4.1 所示.

显然, $E(X|Y = y_1), \dots, E(X|Y = y_j) \dots$ 依赖于 $Y = y_j$, 即依赖于 $\omega \in B_j = \{\omega : Y = y_j\}$, 这样, 从全局样本空间 Ω 及对 $\omega \in \Omega$ 可以变化的观点看, 我们有必要引进一个新的随机变量, 记为 $E(X|Y)$. 对于这个 r.v. $E(X|Y)$, 当 $\omega \in B_j$ 时 (即 $Y = y_j$ 时) 它的取值为 $E(X|Y = y_j)$. 称 r.v. $E(X|Y)$ 为 r.v. X 关于 r.v. Y 的条件数学期望.

为给出 $E(X|Y)$ 的确切定义及表示式, 引进事件的示性函数如下: 记

$$I_{B_j}(\omega) = \begin{cases} 1, & \omega \in B_j = \{\omega : Y(\omega) = y_j\}, \\ 0, & \omega \notin B_j = \{\omega : Y(\omega) = y_j\}. \end{cases}$$

显然 $(I_{B_j}(\omega) = 1) \leftrightarrow (Y = y_j)$ 发生, 亦记 $I_{B_j}(\omega) = I_{(Y=y_j)}(\omega)$.

定义 记

$$E(X|Y) \triangleq \sum_j I_{(Y=y_j)}(\omega) E(X|Y = y_j), \quad (1.4.1)$$

称 $E(X|Y)$ 为 X 关于 Y 的条件数学期望. □

$E(X|Y)$ 的定义包含如下的直观意义:

1° r.v. $E(X|Y)$ 是 r.v. Y 的函数, 当 $\omega \in \{\omega : Y = y_j\}$ 时, $E(X|Y)$ 的取值为 $E(X|Y = y_j)$. 事实上, 它是局部平均 $\{E(X|Y = y_j), j \in N\}$ 的统一表达式.

2° 当 $E(X|Y = y_j) \neq E(X|Y = y_k) (j \neq k)$ 时 $P[E(X|Y) = E(X|Y = y_j)] = P(Y = y_j)$, 否则, 令 $D_j = \{k : E(X|Y = y_k) = E(X|Y = y_j)\}$, 则

$$P\{E(X|Y) = E(X|Y = y_j)\} = \sum_{k \in D_j} P(Y = y_k).$$

3° 由于 r.v. $E(X|Y)$ 是 r.v. Y 的函数, 故它的数学期望应为

$$E(E(X|Y)) = \sum_j E(X|Y = y_j) P(Y = y_j).$$

例: r.v. (X, Y) 的联合分布律如表 1.4.1.

1.4 条件数学期望

Y \ X p _{ij}	X			p _{·j}
	1	2	3	
1	2/27	4/27	1/27	7/27
2	5/27	7/27	3/27	15/27
3	1/27	2/27	2/27	5/27
p _{i·}	8/27	13/27	6/27	

表 1.4.1

试求 $E(X|Y)$ 的分布律, EX 及 $E(E(X|Y))$.

解: 为求 $E(X|Y = j)$, 先求 $P(X = i, Y = j), i, j = 1, 2, 3$. 当 $Y = 1$ 时,

$$P(X = 1|Y = 1) = P(X = 1, Y = 1)/P(Y = 1) = \frac{2}{27}/\frac{7}{27} = \frac{2}{7},$$

同理 $P(X = 2|Y = 1) = 4/7, P(X = 3|Y = 1) = 1/7$. 故

$$E(X|Y = 1) = \sum_{i=1}^3 iP(X = i|Y = 1) = 1 \times \frac{2}{7} + 2 \times \frac{4}{7} + 3 \times \frac{1}{7} = \frac{13}{7}.$$

类似地,

$$E(X|Y = 2) = \sum_{i=1}^3 iP(X = i|Y = 2) = 1 \times \frac{5}{15} + 2 \times \frac{7}{15} + 3 \times \frac{3}{15} = \frac{28}{15},$$

$$E(X|Y = 3) = \sum_{i=1}^3 iP(X = i|Y = 3) = 1 \times \frac{1}{5} + 2 \times \frac{2}{5} + 3 \times \frac{2}{5} = \frac{11}{5}.$$

又 $P\{E(X|Y) = E(X|Y = j)\} = P(Y = j), j = 1, 2, 3$ 故 $E(X|Y)$ 的分布律列表如下:

$E(X Y = j)$	$\frac{13}{7}$	$\frac{28}{15}$	$\frac{11}{5}$
$P\{E(X Y) = E(X Y = j)\} = P(Y = j)$	$\frac{7}{27}$	$\frac{15}{27}$	$\frac{5}{27}$

于是

$$E(E(X|Y)) = (\frac{13}{7})(\frac{7}{27}) + (\frac{28}{15})(\frac{15}{27}) + (\frac{11}{5})(\frac{5}{27}) = \frac{52}{27},$$

而

$$EX = \sum_{i=1}^3 ip(X = i) = 1 \times \frac{8}{27} + 2 \times \frac{13}{27} + 3 \times \frac{6}{27} = \frac{52}{27},$$

得

$$EX = E(E(X|Y)) = \frac{52}{27}. \quad \square$$

自然要问, 一般情形下, 是否 $EX = E(E(X|Y))$? 它的直观意义又是什么? 试证明:

1° 在 (X, Y) 为 d.r.v. 且 $E|X| < \infty$ 时, $EX = E(E(X|Y))$,

2° $E(X|X) = X$.

2. 连续型 r.v. (X, Y) 的情形

设 (X, Y) 的联合概率密度函数 (jointly probability density function 简记 j.p.d.f.) 为 $f(x, y)$, Y 的 p.d.f. 为 $f_Y(y) = \int_{-\infty}^{+\infty} f(x, y) dx$, 设 $f_Y(y) > 0$, $E|X| < \infty$, 给定 $Y = y$, X 的条件概率密度函数 (简记 c.p.d.f.) 为

$$f_{X|Y=y}(x|y) = \frac{f(x, y)}{f_Y(y)},$$

条件分布函数为

$$F_{X|Y=y}(x|y) = P(X \leq x | Y = y) = \int_{-\infty}^x \frac{f(u, y)}{f_Y(y)} du,$$

条件数学期望为

$$E(X|Y = y) = \int_{-\infty}^{+\infty} x f_{X|Y=y}(x|y) dx = \int_{-\infty}^{+\infty} x \frac{f(x, y)}{f_Y(y)} dx. \quad (1.4.2)$$

令 $D \in \mathcal{B}$, 考虑 $Y \in D$ 下, X 的条件分布函数为

$$F(x|D) = P\{X \leq x | Y \in D\} = \frac{P(X \leq x, Y \in D)}{P(Y \in D)} = \frac{\int_{-\infty}^x \left(\int_{y \in D} f(x, y) dy \right) dx}{\int_{y \in D} f_Y(y) dy}.$$

在 $Y \in D$ 下, X 的条件 p.d.f. 为

$$f_{X|D}(x|D) = \frac{\int_{y \in D} f(x, y) dy}{P(Y \in D)}. \quad (1.4.3)$$

于是在 $Y \in D$ 下, X 的条件数学期望定义为

$$E(X|Y \in D) \triangleq \int_{-\infty}^{+\infty} x f_{X|D}(x|D) dx = \int_{y \in D} \left(\int_{-\infty}^{+\infty} x f(x, y) dx \right) dy / P(Y \in D).$$

由上式定义, 有

$$\begin{aligned} E(X|Y \in D) &= \int_{y \in D} \left(\int_{-\infty}^{+\infty} x \frac{f(x, y)}{f_Y(y)} dx \right) f_Y(y) dy / P(Y \in D) \\ &= \frac{1}{P(Y \in D)} \cdot \int_{y \in D} E(X|Y = y) f_Y(y) dy. \end{aligned}$$

1.4 条件数学期望

显然, 条件数学期望 $E(X|Y=y)$ 是 y 的函数. 这样, 从整个样本空间 Ω 及从 $\omega \in \Omega$ 可以变化的宏观上看, 可以且有必要定义一 r.v. $E(X|Y)$, 使其在 $Y=y$ 时, $E(X|Y)$ 的取值为 $E(X|Y=y)$.

定义 设 (X, Y) 具有 j.p.d.f. $f(x, y)$, Y 的 p.d.f. 为 $f_Y(y) > 0, E|X| < \infty$, 若 r.v. $E(X|Y)$ 满足:

- 1° $E(X|Y)$ 是 r.v. Y 的函数, 当 $Y=y$ 时, 它的取值为 $E(X|Y=y)$;
- 2° 对任意 $D \in \mathcal{B}$,

$$E[E(X|Y)|Y \in D] = E(X|Y \in D). \quad (1.4.4)$$

称 r.v. $E(X|Y)$ 为 X 关于 Y 的条件数学期望. □

从定义 1°, 由于 $E(X|Y)$ 是 r.v. Y 的函数, 故它的数学期望应为

$$E[E(X|Y)] = \int_{-\infty}^{+\infty} E(X|Y=y)f_Y(y)dy.$$

而从 2°, 当取 $D = \mathbb{R} = (-\infty, +\infty)$ 时

$$\begin{aligned} EX &= E\{X|Y \in (-\infty, +\infty)\} = E\{E(X|Y)|Y \in (-\infty, +\infty)\} = E[E(X|Y)] \\ &= \int_{-\infty}^{+\infty} E(X|Y=y)f_Y(y)dy. \end{aligned}$$

例: (X, Y) 是二维正态分布. 即 $(X, Y) \sim N(\mu_1, \mu_2, \rho, \sigma_1^2, \sigma_2^2)$. 即 j.p.d.f. 为

$$f(x, y) = \frac{1}{2\pi\sigma_1\sigma_2(1-\rho^2)^{\frac{1}{2}}} \exp\left\{-\frac{1}{2(1-\rho^2)}\left[\frac{(x-\mu_1)^2}{\sigma_1^2} - 2\rho\frac{(x-\mu_1)(y-\mu_2)}{\sigma_1\sigma_2} + \frac{(y-\mu_2)^2}{\sigma_2^2}\right]\right\},$$

则

$$\begin{aligned} f_{Y|X=x}(y|x) &= \frac{f(x, y)}{f_X(x)} = \frac{1}{\sqrt{2\pi}\sigma_2(1-\rho^2)^{\frac{1}{2}}} \exp\left\{-\frac{1}{2\sigma_2^2(1-\rho^2)}\left[y-\mu_2-\rho\frac{\sigma_2}{\sigma_1}(x-\mu_1)\right]^2\right\} \\ &\sim N\left(\mu_2 + \rho\frac{\sigma_2}{\sigma_1}(x-\mu_1), \sigma_2^2(1-\rho^2)\right). \end{aligned}$$

故

$$\begin{aligned} E(Y|X=x) &= \mu_2 + \rho\frac{\sigma_2}{\sigma_1}(x-\mu_1); \\ E(Y|X) &= \mu_2 + \rho\frac{\sigma_2}{\sigma_1}(X-\mu_1). \end{aligned} \quad (1.4.5)$$

此时 $E(Y|X)$ 是 X 的线性函数, 这是正态分布的重要性质.

3. 条件概率与条件分布函数

设 r.v. (X, Y) 及任一随机事件 $B \subset \Omega$, 记

$$I_B(\omega) = \begin{cases} 1 & \omega \in B, \\ 0 & \omega \notin B. \end{cases}$$

即 I_B 是 B 的示性函数. 显然

$$P(B) = E(I_B(\omega)).$$

我们称

$$E(I_B(\omega)|Y) \triangleq P(B|Y)$$

为事件 B 关于 r.v. Y 的条件概率. 此时 $P(B|Y)$ 是 r.v. 且是 Y 的函数, 对于 $\forall x \in \mathbb{R}$, 取 $B = (\omega : X \leq x)$. 称

$$F(x|Y) \triangleq P(X \leq x|Y) = E(I_{(X \leq x)}|Y). \quad (1.4.6)$$

为 X 关于 Y 的条件分布函数.

于是有关条件概率, 条件分布函数均可用条件数学期望的概念及性质来处理.

4. 条件数学期望的基本性质

二个 r.v. Z_1, Z_2 如 $P(Z_1 = Z_2) = 1$, 称 Z_1, Z_2 几乎处处 (或称几乎必然) 相等, 记作 $Z_1 = Z_2$ a.s.

设 r.v. $X, Y, X_i (1 \leq i \leq n), g(x), h(y)$ 为一般函数, 且 $E|X|, E|X_i| < \infty (1 \leq i \leq n), E|g(X)h(Y)| < \infty, E|g(X)| < \infty$. 我们有:

1°

$$E(E(X|Y)) = EX; \quad (1.4.7)$$

2°

$$E\left(\sum_{i=1}^n \alpha_i X_i | Y\right) = \sum_{i=1}^n \alpha_i E(X_i | Y) \text{ a.s.}, \quad (1.4.8)$$

其中 $\alpha_i (1 \leq i \leq n)$ 为常数.

3°

$$E[(g(X)h(Y)|Y)] = h(Y)E(g(X)|Y) \text{ a.s.}, \quad (1.4.9)$$

特别

$$E(X|X) = X \text{ a.s.},$$

$$E[g(X)h(Y)] = E[h(Y)E(g(X)|Y)]. \quad (1.4.10)$$

18

4° 如 X, Y 相互独立, 则

$$E(X|Y) = EX.$$

1.4 条件数学期望

下面仅证 (1.4.10) 式, 其它留作练习.

设 $(X, Y) \sim f(x, y)$, 则

$$\begin{aligned} E(g(X)h(Y)) &= \int_{-\infty}^{+\infty} \int_{-\infty}^{+\infty} g(x)h(y)f(x, y) \, dx \, dy \\ &= \int_{-\infty}^{+\infty} \left[\int_{-\infty}^{+\infty} g(x) \frac{f(x, y)}{f_Y(y)} \, dx \right] h(y)f_Y(y) \, dy \\ &= \int_{-\infty}^{+\infty} E(g(X)|Y=y)h(y)f_Y(y) \, dy \\ &= E[h(Y)E(g(X)|Y)]. \end{aligned}$$

由上面倒数第二式, 有

$$E(g(X)h(Y)) = \int_{-\infty}^{+\infty} E(g(X)|Y=y)h(y)f_Y(y) \, dy, \quad (1.4.11)$$

特别地取 $g(X) = I_A(\omega)$, $h(y) \equiv 1$ 时, 得

$$P(A) = \int_{-\infty}^{+\infty} P(A|Y=y)f_Y(y) \, dy. \quad (1.4.12)$$

(1.4.12) 式是全概率公式的推广.

5. 对多元随机变量的条件数学期望

(1). 离散型随机变量

设三个 r.v. (X, Y, Z) , 其中 (Y, Z) 为 d.r.v., 称 r.v. $E(X|Y, Z)$ 是 X 关于 Y, Z 的条件数学期望, 若它满足:

1° $E(X|Y, Z)$ 是 (Y, Z) 的二元函数, 当 $Y = y_j; Z = z_k$ 时, $E(X|Y, Z)$ 的取值为 $E(X|Y = y_j; Z = z_k)$;

2° 对任意 $D_j \in \mathbb{R}^1, D_k \in \mathbb{R}^1$,

$$E[E(X|Y, Z)|Y \in D_j, Z \in D_k] = E(X|Y \in D_j, Z \in D_k),$$

用示性函数表示, 即

$$E(X|Y, Z) \triangleq \sum_j \sum_k I_{(Y=y_j, Z=z_k)}(\omega) E(X|Y = y_j, Z = z_k).$$

(2). 连续型随机变量

如 (X, Y, Z) 为 c.r.v. (连续型 r.v.), j.p.d.f. 为 $f(x, y, z)$, (Y, Z) 的 j.p.d.f. 为 $f_{Y,Z}(y, z)$, X 关于 $Y = y, Z = z$ 的条件 p.d.f. 为

$$f_{X|(Y,Z)=(y,z)}(x|y, z) = f(x, y, z) / f_{Y,Z}(y, z),$$

设 $E|X| < \infty, f_{Y,Z}(y, z) > 0$, 则 r.v. $E(X|Y, Z)$ 满足:

- 1° $E(X|Y, Z)$ 是 Y, Z 的函数, 当 $Y = y, Z = z$ 时, 它们取值为 $E(X|Y = y, Z = z)$.
- 2° 对任意, $D_1 \subset \mathbb{R}^1, D_2 \subset \mathbb{R}^1$,

$$E\{(E(X|Y, Z)|Y \in D_1, Z \in D_2)\} = E(X|Y \in D_1, Z \in D_2).$$

(3). n 元随机变量

对 d.r.v. $\{X, Y_k, 1 \leq k \leq n\}$ 的情况, 称

$$E(X|Y_1, \dots, Y_n) \triangleq \sum_{j_1} \cdots \sum_{j_n} I_{(Y_k=j_k, 1 \leq k \leq n)}(\omega) E(X|Y_1 = j_1, Y_2 = j_2, \dots, Y_n = j_n)$$

为 X 关于 (Y_1, \dots, Y_n) 的条件数学期望.

若 $E|X|, E|X_i| < \infty, 1 \leq i \leq 2, E|g(Y_1, \dots, Y_n)| < \infty$, 则类似有:

- 1° $E(\alpha_1 X_1 + \alpha_2 X_2 | Y_1, \dots, Y_n) = \sum_{i=1}^2 \alpha_i E(X_i | Y_1, \dots, Y_n)$ a.s.;
- 2° $E[g(Y_1, \dots, Y_n) X | Y_1, \dots, Y_n] = g(Y_1, \dots, Y_n) E(X | Y_1, \dots, Y_n)$ a.s.;
- 3° 如 X 与 Y_1, \dots, Y_n 独立, 则 $E(X | Y_1, \dots, Y_n) = EX$ a.s..

证明从略.

6. 条件乘法公式与条件独立性

(1). 条件概率的乘法公式

设 A, B 为两个随机事件, 由条件概率的定义可知

$$P(AB) = P(A)P(B|A).$$

与上面的概率乘法公式类似, 我们有条件概率的乘法公式如下:

命题 1.4.1 设 A, B, C 为三个随机事件, 则

$$P(BC|A) = P(B|A)P(C|AB). \quad (1.4.13)$$

证: 按条件概率的定义, 当 $P(AB) > 0$ 时

$$P(BC|A) = \frac{P(ABC)}{P(A)} = \frac{P(AB)}{P(A)} \frac{P(ABC)}{P(AB)} = P(B|A)P(C|AB).$$

因此按我们对条件概率的等式的有关约定, (1.4.13) 式成立. □

1.5 随机过程的概念

(2). 条件独立性

我们知道, 当两个随机事件 A, B 独立时, 有 $P(AB) = P(A)P(B)$ 即 $P(A|B) = P(A)$. 同样, 与上面的独立性概念类似, 我们有条件独立性的定义如下:

定义 设 A, B, C 为三个随机事件, 称事件 A, C 相对于事件 B **条件独立**, 若满足

$$P(C|AB) = P(C|B). \quad (1.4.14)$$

对于条件独立性我们有如下结论:

命题 1.4.2 设 A, B, C 为三个随机事件, 则事件 A, C 相对于事件 B 条件独立的充要条件为

$$P(AC|B) = P(A|B)P(C|B). \quad (1.4.15)$$

证: 必要性. 由命题 1.4.1

$$P(AC|B) = P(A|B)P(C|AB),$$

当 $P(AB) = 0$ 时, $P(A|B) = 0$, 因此 (1.4.15) 式两边均为 0, 而当 $P(AB) > 0$ 时, 将 (1.4.14) 式代入上式即得 (1.4.15) 式.

充分性. 只需考虑 $P(AB) > 0$ 的情形, 由命题 1.4.1 及 (1.4.15) 式可得

$$P(C|AB) = \frac{P(AC|B)}{P(A|B)} = P(C|B). \quad \square$$

§ 1.5 随机过程的概念

在概率论中, 我们研究了随机变量, n 维随机向量. 在极限定理中, 涉及到了无穷多个随机变量, 但局限在它们之间是相互独立的情形. 上述情形加以推广, 即研究一族无穷多个, 相互有关的随机变量, 这就是随机过程.

1. 概念

设对每一个参数 $t \in T$, $X(t, \omega)$ 是一随机变量, 我们称随机变量族 $X_T = \{X(t, \omega), t \in T\}$ 为一 **随机过程**(stochastic process) 或称随机函数. 其中 $T \subset \mathbb{R}$ 是一实数集, 称为指标集.

用映射来表示 X_T ,

$$X(t, \omega) : T \times \Omega \rightarrow \mathbb{R}.$$

即 $X(\cdot, \cdot)$ 是定义在 $T \times \Omega$ 上的二元单值函数, 固定 $t \in T$, $X(t, \cdot)$ 是定义在样本空间 Ω 上的函数, 即为一 r.v.. 对于 $\omega \in \Omega$, $X(\cdot, \omega)$ (t 在 T 中顺序变化) 是参数 $t \in T$ 的一般函数,

通常称 $X(\cdot, \omega)$ 为样本函数, 或称随机过程的一个实现, 或说是一条轨道. 记号 $X(t, \omega)$ 有时也写为 $X_t(\omega)$ 或简记为 $X(t)$ 或 X_t .

参数 $t \in T$ 一般表示时间或空间. 参数集 T 常用的有三种: (1) $T_1 = N_0 = \{0, 1, 2, \dots\}$, (2) $T_2 = Z = \{\dots - 2, -1, 0, 1, 2, \dots\}$, (3) $T_3 = [a, b]$. 其中 a 可以取 $-\infty$ 或 0 , b 可以取 $+\infty$. 当 T 取可列集 (T_1 或 T_2) 时, 通常称 X_T 为随机序列.

X_T 的取值也可以是复数, \mathbb{R}^n 或更一般的抽象空间. $X_t (t \in T)$ 可能取值的全体之集称为 **状态空间**. 记作 S . S 中的元素称为状态.

2. 例子

1° 质点在直线上的随机游动. 设一质点在时刻 $t = 0$ 时处于位置 a (整数), 以后每隔单位时间, 分别以概率 p 及 $q = 1 - p$ 向正的或负的方向随机移动一个单位, 记 X_n 为质点在时刻 $t = n$ 的位置. 固定 n , X_n 是 r.v. 考虑不同的 n 时, $\{X_n, n \geq 0\}$ 是一随机序列.

2° 考虑某“服务站”在 $[0, t]$ 内来的“顾客”数记为 $N(t)$, 固定 t , $N(t)$ 就是一随机变量. 因此 $\{N(t), t \geq 0\}$ 是一随机过程. 这里的“顾客”可以是电话的“呼唤”, 通讯设备中的“信号”, 一个系统的“更换设备”, 放散性物质衰变的“粒子”等.

3° 在外界是随机载荷条件下, 某零件 t 时的应力 $X(t)$ 是随机的, 故 $\{X(t), t \in T\}$ 是一随机过程. $X(t)$ 亦可表示某电路中的电压, 设备的温度, 河流的流量 (或水位), 气体的压力等等.

4° 考虑某输入输出系统, 例如最简单的 R-C 电路, 设输入端有一个干扰信号电压记为 $\xi(t)$, 记 $Q(t)$ 为 t 时电路的电量, 则它满足

$$R \frac{dQ(t)}{dt} + \frac{1}{C} Q(t) = \xi(t).$$

由于 $\{\xi(t), t \in T\}$ 是一随机过程, 容易理解 $\{Q(t), t \in T\}$ 也是一随机过程, 上式是一个最简单的随机微分方程.

3. 随机过程的数字特征及有限维分布函数族

设 $\{X(t), t \in T\}$ 是一随机过程. 为了刻画它的概率特征, 通常用它的均值函数, 方差函数, 协方差函数 (相关函数) 以及有限维分布函数族及特征函数族等.

(1). 均值函数

随机过程 $\{X(t), t \in T\}$ 的均值函数定义为 (以下均假定右端存在):

$$m(t) \triangleq E(X(t)).$$

1.5 随机过程的概念

(2). 方差函数

随机过程 $\{X(t), t \in T\}$ 的方差函数定义为：

$$D(t) \triangleq E\{(X(t) - m(t))^2\}.$$

(3). 协方差函数

随机过程 $\{X(t), t \in T\}$ 的协方差函数定义为：

$$R(s, t) \triangleq \text{Cov}(X(s), X(t)).$$

(4). 相关函数

随机过程 $\{X(t), t \in T\}$ 的相关函数定义为：

$$\rho(s, t) \triangleq \frac{\text{Cov}(X(s), X(t))}{\sqrt{D(t) \cdot D(s)}}.$$

(5). 有限维分布族

设 $t_i \in T, 1 \leq i \leq n$ (n 为任意正整数), 记

$$F(t_1, t_2, \dots, t_n; x_1, x_2, \dots, x_n) = P(X(t_1) \leq x_1, X(t_2) \leq x_2, \dots, X(t_n) \leq x_n),$$

其全体

$$\{F(t_1, t_2, \dots, t_n, x_1, x_2, \dots, x_n), t_1, t_2, \dots, t_n \in T, n \geq 1\}$$

称为随机过程的 **有限维分布族**. 它具有以下二个性质：

1° 对称性 对 $(1, 2, \dots, n)$ 的任一排列 (j_1, j_2, \dots, j_n) , 有

$$F(t_{j_1} t_{j_2}, \dots, t_{j_n}; x_{j_1} x_{j_2}, \dots, x_{j_n}) = F(t_1, t_2, \dots, t_n; x_1, x_2, \dots, x_n).$$

2° 相容性 对 $m < n$, 有

$$F(t_1, \dots, t_m, t_{m+1}, \dots, t_n; x_1, \dots, x_m, \infty, \dots, \infty) = F(t_1, \dots, t_m; x_1, \dots, x_m).$$

一个随机过程的概率特性完全由其有限维分布族决定.

(6). 特征函数

记

$$\begin{aligned}\phi(t_1, t_2, \dots, t_n; \theta_1, \dots, \theta_n) &= E\{\exp\{i[\theta_1 X(t_1) + \dots + \theta_n X(t_n)]\}\} \\ &= \int_{-\infty}^{+\infty} \dots \int_{-\infty}^{+\infty} \exp\{i[\theta_1 x_1 + \dots + \theta_n x_n]\} F(t_1, \dots, t_n; dx_1, \dots, dx_n),\end{aligned}$$

称 $\{\phi(t_1, \dots, t_n; \theta_1, \dots, \theta_n), n \geq 1, t_1, \dots, t_n \in T\}$ 为随机过程 $\{X(t), t \in T\}$ 的有限维特征函数族.

§ 1.6 随机过程的分类

设 $X_T = \{X(t), t \in T\}$ 为随机过程, 按其概率特征, 分类如下:

1. 独立增量过程

对 $t_1 < t_2 < \dots < t_n, t_i \in T, 1 \leq i \leq n$, 若增量

$$X(t_1), X(t_2) - X(t_1), X(t_3) - X(t_2), \dots, X(t_n) - X(t_{n-1})$$

相互独立, 则称 $\{X(t), t \in T\}$ 为 **独立增量过程**(Process with independent increments). 若对一切 $0 \leq s < t$, 增量 $X(t) - X(s)$ 的分布只依赖于 $t - s$, 则称 X_T 有平稳增量. 有平稳增量的独立增量过程简称为独立平稳增量过程.

常见的泊松 (Poisson) 过程和维纳 (Wiener) 过程 (或称 Brownian motion) 就是二个最简单也是最重要的独立平稳增量过程.

2. 马氏过程 (Markov process)

粗略地说, 一随机过程, 若已知现在的 t 状态 X_t , 那么将来状态 $X_u (u > t)$ 取值 (或取某些状态) 的概率与过去状态 $X_s (s < t)$ 取值无关, 或更简单地说, 已知现在, 将来与过去无关 (条件独立), 则称此性质为马尔可夫性 (无后效性或简称为马氏性). 具有这种马氏性的过程称为马氏过程. 精确定义为:

随机过程 $\{X_t, t \in T\}$, 若对任意 $t_1 < t_2 < \dots < t_n < t, x_i, 1 \leq i \leq n$, 及 $A \subset \mathbb{R}$, 总有

$$P(X_t \in A | X_{t_1} = x_1, X_{t_2} = x_2, \dots, X_{t_n} = x_n) = P(X_t \in A | X_{t_n} = x_n),$$

则称此过程为 **马尔可夫过程**(Markov Process). 24

我们称 $P(s, x; t, A) = P(X_t \in A | X_s = x), s < t$, 为转移概率函数 (transition probability function).

1.6 随机过程的分类

X_t 的取值全体构成的集合记为 S , 称为状态空间. 对于马氏过程 $X_T = \{X_t, t \in T\}$, 当 $S = \{1, 2, 3, \dots\}$ 为可列无限集或有限集时, 通常称为马氏链 (马尔可夫链, Markov chain). 样本函数是连续的马氏过程 $\{X_t, t \in [0, \infty]\}$ 称为扩散 (diffusion) 过程. Poisson 过程是一个最简单连续时间马氏链, 而 Brownian Motion 则是一个最简单的扩散过程.

3. 平稳过程及二阶矩过程

(1). 宽平稳过程 (或协方差平稳过程)

一随机过程 X_T , 若对 $\forall \tau, t \in T, D(X(t))$ 存在且 $E(X(t)) = m$, $\text{Cov}(X_t, X_{t+\tau}) = R(\tau)$ 仅依赖 τ , 则称 X_T 为 **宽平稳过程** (wide sense stationary process), 即它的协方差不随时间推移而改变.

(2). 二阶矩过程

一随机过程 X_T , 若对 $\forall t \in T, DX_t$ 存在, 则称为 **二阶矩过程** (finite second moments process).

(3). 严平稳过程

一随机过程 X_T , 若对 $\forall t_1, t_2, \dots, t_n \in T$, 及 $h > 0$, $(X_{t_1}, X_{t_2}, \dots, X_{t_n})$ 与 $(X_{t_1+h}, X_{t_2+h}, \dots, X_{t_n+h})$ 有相同的联合分布, 则称该过程为 **严平稳过程** (strictly stationary process). 严平稳过程的一切有限维分布对时间的推移保持不变. 特别, $X(t), X(s)$ 的二维分布只依赖于 $t - s$.

尽管从实际应用的角度来看要求追溯到无穷的过去似乎有点不现实, 但为数学讨论方便, 平稳过程 (包括宽、严两种情况) 的指标集应取为 $(-\infty, +\infty)$ 或全体整数 (离散时间情形).

4. 鞅 (Martingales)

若对 $\forall t \in T, E|X(t)| < \infty$, 且对 $\forall t_1, t_2 < \dots < t_n < t_{n+1}$ 有

$$E(X(t_{n+1})|X(t_1), X(t_2), \dots, X(t_n)) = X(t_n) \quad \text{a.s.},$$

则称 $\{X(t), t \in T\}$ 为 **鞅**.

近十多年, 鞅在现代科技中有越来越广泛的应用.

5. 更新过程 (Renewal Process)

设 $(X_k, k \geq 1)$ 为独立同分布的正的随机变量序列, 对 $\forall t > 0$, 令 $S_0 = 0, S_n = \sum_{k=1}^n X_k$, 并定义

$$N(t) = \max\{n : n \geq 0, S_n \leq t\},$$

称 $\{N(t), t \geq 0\}$ 为 **更新过程**.

$N(t)$ 可以解释为 $[0, t]$ 内更换零件的个数或系统来的信号 (粒子) 数, 或 “服务站” 来的 “顾客数” 等.

6. 点过程 (或称计数过程)(point process)

一个随机过程 $\{N(A), A \subset T\}$ 是一点过程, 若 $N(A)$ 表示在集合 A 中 “事件” 发生的总数. 即它满足:

1° 对 $\forall A \subset T, N(A)$ 是一取值非负整数的随机变量 ($N(\emptyset) = 0$);

2° 对 $\forall A_1, A_2 \subset T$, 若 $A_1 A_2 = \emptyset$, 则对每一个样本有 $N(A_1 \cup A_2) = N(A_1) + N(A_2)$.

注: 参数集 T 可以是 \mathbb{R}^n , 也可以是任意一抽象非空集.

Poisson 过程是简单的点过程.

练习题

1.1 设 N 为取值非负整数的随机变量, 证

$$EN = \sum_{n=1}^{\infty} P(N \geq n) = \sum_{n=0}^{\infty} P(N > n),$$

设 X 是非负随机变量, 具有分布函数 $F(x)$, 证

$$EX = \int_0^{\infty} (1 - F(x)) dx, \quad E(X^n) = \int_0^{\infty} nx^{n-1}(1 - F(x)) dx \quad (n \geq 1).$$

1.2 设 X_1, X_2, \dots, X_n 独立同 0-1 分布, 即 $P(X_n = 1) = p \geq 0, P(X_n = 0) = q \geq 0, p + q = 1$, 令 $A = \{X_1 + X_2 = 0\}, B = \{X_2 + X_3 = 2\}, C = \{X_2 + X_3 = 1\}$. 试问 A 与 B 是否相容? 是否独立? A 与 C 是否相容? 说明理由. 并求

$$P\left(\sum_{i=1}^n X_i = k\right), \quad 0 \leq k \leq n.$$

1.3 设 N_1, N_2, N_3 独立, N_i 是参数为 λ_i 的 Poisson 分布, $i = 1, 2, 3$.

1. 求 $P(N_1 + N_2 = n), n \in \mathbb{N}$; 26

2. 求 $P(N_1 = k | N_1 + N_2 = n), 0 \leq k \leq n$;

3. 证 $N_1 + N_2$ 与 N_3 独立;

练习题

4. 求 $E(N_1|N_1+N_2)$ 及 $E(N_1+N_2|N_1)$.
- 1.4 (a) 若 X 是一连续型随机变量, 其分布函数为 $F(x)$. 证明 $Y = F(X)$ 是 $[0, 1]$ 上均匀分布的随机变量.
- (b) 如果 U 是 $[0, 1]$ 上均匀分布的随机变量, $F(x)$ 是一给定的分布函数. 则 $Z = F^{-1}(U)$ 的分布函数为 $F(x)$, 其中 F^{-1} 记为 F 的反函数.
- 1.5 设 $X_1, X_2, \dots, X_n, \dots$ 独立同 0-1 分布. 且有 $P(X_n = 1) = p = 1 - P(X_n = 0), 0 < p < 1$, N 是参数为 λ 的 Poisson 分布, 且与 $\{X_n\}$ 独立. $\xi = X_1 + X_2 + \dots + X_N = \sum_{i=1}^N X_i$, 求 ξ 的分布, $E\xi$ 及 $D\xi$.
- 1.6 设 $\{X_t, t \geq 0\}$ 是取值整数的独立增量过程, 证明它是一马氏过程.
- 1.7 设 $\{X_n, n \geq 1\}$ 是独立同分布的, 而且 $EX_n = 0, E|X_n| < \infty$. 设: $S_n = \sum_{k=1}^n X_k$. 证明 $\{S_n, n \geq 1\}$ 是鞅.
- 1.8 设 $\{\varepsilon_n, n \geq 1\}$ 独立同分布, $\varepsilon_n \sim N(0, \sigma^2), X_0 = 0, X_n = aX_{n-1} + \varepsilon_n \quad (n \geq 1, |a| < 1)$ 试求
1. DX_n 与 $\rho_{nm} = \frac{\text{Cov}(X_n, X_m)}{\sqrt{DX_n DX_m}} \quad (m \geq n)$ 及 $\lim_{n \rightarrow \infty} DX_n$.
 2. $E(X_n|X_1, X_2, \dots, X_{n-1})$ 及 $E(X_4|X_1, X_2)$.
- 1.9 设 X 与 Y 是离散型随机变量, 定义条件方差 $D(X|Y) = E[(X - E(X|Y))^2|Y]$, 证明: $DX = E(D(X|Y)) + D(E(X|Y))$.
- 1.10 设 X_1, X_2, \dots, X_n 独立, X_i 是参数为 λ_i 的指数分布, $1 \leq i \leq n, X_{(1)} \leq \dots \leq X_{(n)}$ 为相应的顺序统计量, 求:
1. $\lambda_i = \lambda$ 时 $(X_{(n)}, X_{(1)})$ 的联合概率密度函数;
 2. $\lambda_i = \lambda$ 时 $X_{(i)}$ 的概率密度函数 $(1 \leq i \leq n)$;
 3. $X_1 + X_2$ 的分布函数;
 4. $(X_{(2)}, X_{(3)})$ 的联合概率密度函数 $(n \geq 3)$;
 5. $\forall t > 0$, 证明: $P(X_1 < X_2 | \min(X_1, X_2) = t) = \lambda_1/(\lambda_1 + \lambda_2)$.
- 1.11 设 $X_1, X_2, \dots, X_n, \dots$ 是独立同分布, 取值非负整数的随机变量, 记 $X_0 = 0$, 若 $X_n > \max(X_0, X_1, \dots, X_{n-1})$ 称在 n 时刻一个新记录发生.
1. 记 N_n 为 n 时刻 (包括 n 时刻) 创新纪录的次数, 求 EN_n 及 DN_n ;
 2. 记 $T_y = \min\{n: X_n > y\}$ 为创纪录超过 y 的时刻, 求: $P(T_y = n) \quad (n = 2, 3)$.
- 1.12 设 X 与 Y 独立且 $P(X = i) = f(i), P(Y = j) = g(j), f(i), g(i) > 0, i, j \in N, \sum_{i=0}^{\infty} f(i) = \sum_{i=0}^{\infty} g(i) = 1$ 设

$$P(X = k|X + Y = l) = \begin{cases} C_l^k p_k (1-p)^{l-k}, & 0 \leq k \leq l, \\ 0, & k > l. \end{cases}$$

1. 证明:

$$f(i) = \frac{(\theta\alpha)^i}{i!} \exp(-\theta\alpha), \quad g(i) = \frac{\theta^i}{i!} \exp(-\theta) \quad (i \in N),$$

其中 $\alpha = p/(1-p)$, 且 $\theta > 0$ 为任意实数.

2. 令 $F(s) = \sum_{i=0}^{\infty} f(i)s^i, G(s) = \sum_{i=0}^{\infty} g(i)s^i$, 证明:

$$F(u)F(v) = F(vp + (1-p)u)G(vp + (1-p)u),$$

且 p 满足条件: $G(\frac{1}{1-p}) = \frac{1}{f(0)}$.

1.13 设 (X, Y) 是取值非负整数的二维 r.v. 其联合母函数为

$$\phi_{X,Y}(s, t) = \sum_{i,j=0}^{\infty} s^i t^j P(X=i, Y=j), \quad |s|, |t| < 1,$$

及各自的母函数为

$$\phi_X(s) = \sum_{i=0}^{\infty} s^i P(X=i), \quad \phi_Y(t) = \sum_{j=0}^{\infty} t^j P(Y=j).$$

证明 X, Y 独立的充要条件是

$$\phi_{X,Y}(s, t) = \phi_X(s)\phi_Y(t), \quad \forall |s| < 1, |t| < 1.$$

1.14 设 X, Y, Z 为三维离散型 r.v. $E|X| < \infty$, 证

$$E[E(X|Y, Z)|Y] = E(X|Y) = E[E(X|Y)|Y, Z],$$

并说明其直观意义.

1.15 设 $X \sim N(\mu, \sigma^2)$, 求 X 在 $X \geq 0$ 下的条件概率密度函数, 及当 $\mu = 2, \sigma = 1$ 时的 $E(X|X \geq 0)$.

1.16 设 X_1, X_2, \dots 独立同分布, 且 X_i 是 $(0, t)$ 上的均匀分布, 求其顺序统计量 $X_{(1)} \leq X_{(2)} \leq \dots \leq X_{(n)}$ 的联合概率密度.

1.17 设 X_1, X_2 相互独立且 X_i 是参数为 λ_i ($i = 1, 2$) 的指数分布, 令 $Z = \min(X_1, X_2)$, 求 Z 在给定 $Z = X_1$ 下的条件分布函数.

1.18 设随机过程 $\{X_i(t), t \geq 0\}$ 为:

1. $X_1(t) = Y_1 + Y_2 t$, 其中 Y_1, Y_2 iid $\sim N(0, 1^2)$;

2. $X_2(t) = \xi \cos(\omega t + \phi)$, 其中 $\omega > 0$ 为常数, ξ, ϕ 为独立 r.v., $\xi \sim N(0, \sigma^2), \phi \sim U[0, 2\pi]$;

3. $X_3(t) = \sum_{k=-\infty}^{+\infty} \xi_k e^{i\lambda_k t}$, 其中 $i = \sqrt{-1}$, $\lambda_k > 0$ 为常数, ξ_k 为 r.v., 且 $E\xi_k = 0$, $E\xi_k \xi_l = 0$ ($l \neq k$), $E\xi_k^2 = \sigma_k^2 > 0$.

练习题

求：

1. $m_i(t) = EX_i(t)$, $D_i(t) = \text{Var } X_i(t)$, $R_i(t_1, t_2) = \text{Cov}(X_i(t_1), X_i(t_2))$, ($i = 1, 2, 3$);
2. $X_1(t)$ 的一维与二维分布.

1.19 设随机过程 $\{B(t), t \geq 0\}$ 是独立增量过程, 且 $\forall s, t \geq 0, B(s+t) - B(s) \sim N(0, t)$.

1. 令

$$X_1(t) = \begin{cases} tB(\frac{1}{t}), & t > 0, \\ 0, & t = 0, \end{cases}$$

求证 $\{X_1(t), t > 0\}$ 为独立增量过程, 并求它的一维与二维分布;

2. 令

$$X_2(t) = \begin{cases} 1, & B(t) \geq x, \\ 0, & B(t) < x, \end{cases} \quad (x \in \mathbb{R}^1 \text{ 为给定常数})$$

求 $EX_2(t)$ 与 $R(t_1, t_2)$.

第二章 Poisson 过程及其推广

§ 2.1 定义与背景

Poisson 过程最早是由法国人 Poisson 于 1837 年引入的, 故得名.

定义 一随机过程 $\{N(t), t \geq 0\}$ 称为 **时齐 Poisson 过程**, 若满足:

1° 是一计数过程, 且 $N(0) = 0$;

2° 是独立增量过程, 即任取 $0 < t_1 < t_2 < \cdots < t_n$,

$$N(t_1), N(t_2) - N(t_1), \cdots, N(t_n) - N(t_{n-1})$$

相互独立;

3° 增量平稳性, 即 $\forall s, t \geq 0, n \geq 0, P[N(s+t) - N(s) = n] = P[N(t) = n]$;

4° 对任意 $t > 0$ 和充分小的 $\Delta t > 0$, 有

$$\begin{cases} P[N(t + \Delta t) - N(t) = 1] = \lambda \Delta t + o(\Delta t), \\ P[N(t + \Delta t) - N(t) \geq 2] = o(\Delta t). \end{cases} \quad (2.1.1)$$

其中 $\lambda > 0$ (称为强度常数), 且 $\lim_{\Delta t \rightarrow 0} \frac{o(\Delta t)}{\Delta t} = 0$. □

时齐 Poisson 过程 (有时简称为 Poisson 流), 是一种典型又简单的, 应用极其广泛的随机过程. $N(t)$ 可表示在 $[0, t]$ 时间随机事件发生的个数. 它可用于刻画“顾客流”, “粒子流”, “信号流”等的概率特性.

背景: 考虑其电话交换台在 $[0, t]$ 内来的呼唤数, 记为 $N(t)$. 显然它是一计数过程. 若它是一平稳独立增量过程, 且在一很短时间间隔 Δt 内来一次呼唤的概率与 Δt 成正比, 来一次以上呼唤的概率是 (Δt) 的高阶无穷小, 则 $\{N(t), t \geq 0\}$ 就是 Poisson 过程. $N(t)$ 表示在 $[0, t]$ 内事件发生的个数. 有以下重要定理:

定理 2.1.1 若 $\{N(t), t \geq 0\}$ 为 Poisson 过程 (简记 P.P.), 则 $\forall s, t \geq 0$, 有

$$P[N(s+t) - N(s) = k] = \frac{(\lambda t)^k}{k!} e^{-\lambda t}, \quad k \in \mathbb{N}, \quad (2.1.2)$$

即 $N(t+s) - N(s)$ 是参数为 λt 的 Poisson 分布.

证: 由增量平稳性, 记 $P_n(t) = P(N(t) = n) = P(N(s+t) - N(s) = n)$. 先看 $n = 0$ 的情形. 因

$$(N(t+h) = 0) = (N(t) = 0, N(t+h) - N(t) = 0), \quad h > 0.$$

故

$$P_0(t+h) = P(N(t+h) = 0) = P(N(t) = 0, N(t+h) - N(t) = 0)$$

2.1 定义与背景

$$\begin{aligned} &= P(N(t) = 0)P(N(t+h) - N(t) = 0) \quad (\text{增量独立}) \\ &= P_0(t)P_0(h). \end{aligned}$$

另一方面

$$P_0(h) = P(N(t+h) - N(t) = 0) = 1 - (\lambda h + o(h)),$$

代入上式, 有

$$\frac{P_0(t+h) - P_0(t)}{h} = -(\lambda P_0(t) + \frac{o(h)}{h}).$$

令 $h \rightarrow 0$, 两边取极限, 得

$$P'_0(t) = -\lambda P_0(t)$$

这是一阶线性常系数微分方程. 由初始条件 $P_0(0) = P(N(0) = 0) = 1$, 可得

$$P_0(t) = e^{-\lambda t}.$$

再看 $n > 0$ 的情形, 因

$$\begin{aligned} \{N(t+h) = n\} &= \{N(t) = n, N(t+h) - N(t) = 0\} \\ &\quad \bigcup \{N(t) = n-1, N(t+h) - N(t) = 1\} \\ &\quad \bigcup \left\{ \bigcup_{l=2}^n (N(t) = n-l, N(t+h) - N(t) = l) \right\} \end{aligned}$$

故

$$P_n(t+h) = P_n(t)(1 - \lambda h - o(h)) + P_{n-1}(t)(\lambda h + o(h)) + o(h).$$

化简可得

$$\frac{P_n(t+h) - P_n(t)}{h} = -\lambda P_n(t) + \lambda P_{n-1}(t) + \frac{o(h)}{h}.$$

令 $h \rightarrow 0$, 两边取极限, 有

$$P'_n(t) = -\lambda P_n(t) + \lambda P_{n-1}(t).$$

且初始条件

$$P_n(0) = P(N(0) = n) = 0.$$

即

$$\frac{d}{dt}[e^{\lambda t} P_n(t)] = \lambda e^{\lambda t} P_{n-1}(t).$$

当 $n = 1$ 时

$$\frac{d}{dt}[e^{\lambda t} P_1(t)] = \lambda.$$

注意到初始条件 $P_1(0) = 0$, 可得

$$P_1(t) = (\lambda t)e^{-\lambda t}.$$

再用归纳法即有

$$P_n(t) = \frac{(\lambda t)^n}{n!} e^{-\lambda t}. \quad \square$$

本定理的证明方法有典型意义.

为了应用方便, 我们给出以下等价定义:

定义: 一计数过程 $\{N(t), t \geq 0\}$ 称为参数是 λ 时齐 Poisson 过程, 若满足:

1° $N(0) = 0$;

2° 是独立增量过程;

3° $\forall s, t \geq 0, N(s+t) - N(s) \sim P(\lambda t)$, 即其增量是参数为 λt 的 Poisson 分布.

证: 留作读者练习.

§ 2.2 相邻事件的时间间隔, Poisson 过程与指数分布的关系

本节从过程的样本函数的特性来刻画 Poisson 过程, 从而揭示它与指数分布之间的内在联系.

设 $\{N(t), t \geq 0\}$ 是一计数过程, $N(t)$ 表示在 $[0, t]$ 内事件发生 (或“顾客”到达) 的个数. 令 $S_0 = 0, S_n$ 表示第 n 个事件发生的时刻 ($n \geq 1$), $X_n = S_n - S_{n-1}$ ($n \geq 1$) 表示第 $(n-1)$ 个事件与第 n 个事件发生的时间间隔. 用式子表示为

$$S_0 = 0,$$

$$S_n = \inf\{t : t > S_{n-1}, N(t) = n\}, \quad n \geq 1.$$

注意, 此时对 $t \geq 0$, 下列事件等价:

$$(N(t) \geq n) = (S_n \leq t)$$

$$(N(t) = n) = (S_n \leq t < S_{n+1}) = (S_n \leq t) - (S_{n+1} \leq t).$$

这里 $\inf\{t\}$ 表示集合 $\{t\}$ 的下确界, 即集合的最大下界, 例如 $\inf\{\frac{1}{n} : n = 1, 2, \dots\} = 0$.

则 $\forall t \geq 0, n \geq 0$, 有 $\{S_n \leq t\} = \{N(t) \geq n\}, \{N(t) = n\} = \{S_n \leq t < S_{n+1}\}$.

因此, S_n 的分布函数为: $t < 0$ 时, $P(S_n \leq t) = 0$; 当 $t \geq 0$ 时,

$$P(S_n \leq t) = P(N(t) \geq n) = 1 - e^{-\lambda t} \left(\sum_{k=0}^{n-1} \frac{(\lambda t)^k}{k!} \right) \quad (2.2.1)$$

S_n 的 p.d.f. 为

$$f_{S_n}(t) = \frac{\lambda(\lambda t)^{n-1}}{(n-1)!} e^{-\lambda t} I_{(t \geq 0)}.$$

特别是当 $n = 1$ 时, 有

32

$$P(X_1 \leq t) = P(S_1 \leq t) = (1 - e^{-\lambda t}) I_{(t \geq 0)}$$

2.2 相邻事件的时间间隔, Poisson 过程与指数分布的关系

即 $X_1 \sim E(\lambda)$ 是参数为 λ 的指数分布. 那么, X_2, \dots, X_n, \dots 又如何呢? 它们之间关系又会怎样呢? 我们有如下漂亮的结果:

定理 2.2.1 计数过程 $\{N(t), t \geq 0\}$ 是 Poisson 过程的充分必要条件是 $\{X_n, n \geq 1\}$ 是独立同参数为 λ 的指数分布.

证: 先证必要性. 步骤如下:

第一步求 (S_1, S_2, \dots, S_n) 的联合概率密度. 令 $t_1 < t_2 < \dots < t_n$, 取充分小的 $h > 0$, 使

$$t_1 - \frac{h}{2} < t_1 < t_1 + \frac{h}{2} < t_2 - \frac{h}{2} < t_2 < t_2 + \frac{h}{2} \cdots < t_{n-1} + \frac{h}{2} < t_n - \frac{h}{2} < t_n < t_n + \frac{h}{2},$$

由

$$\begin{aligned} & \left\{ t_1 - \frac{h}{2} \leq S_1 \leq t_1 + \frac{h}{2} < t_2 - \frac{h}{2} \leq S_2 \leq t_2 + \frac{h}{2} < \cdots < t_n - \frac{h}{2} \leq S_n \leq t_n + \frac{h}{2} \right\} \\ &= \left\{ N(t_1 - \frac{h}{2}) = 0, N(t_1 + \frac{h}{2}) - N(t_1 - \frac{h}{2}) = 1, \right. \\ & \quad \left. N(t_2 - \frac{h}{2}) - N(t_1 + \frac{h}{2}) = 0, \dots, N(t_n + \frac{h}{2}) - N(t_n - \frac{h}{2}) = 1 \right\} \bigcup H_n \end{aligned}$$

其中

$$H_n = \{N(t_1 - \frac{h}{2}) = 0, N(t_1 + \frac{h}{2}) - N(t_1 - \frac{h}{2}) = 1, \dots, N(t_n + \frac{h}{2}) - N(t_n - \frac{h}{2}) \geq 2\}$$

得

$$\begin{aligned} P\{t_1 - \frac{h}{2} \leq S_1 \leq t_1 + \frac{h}{2} < t_2 - \frac{h}{2} \leq S_2 \leq t_2 + \frac{h}{2} < \cdots < t_n - \frac{h}{2} \leq S_n \leq t_n + \frac{h}{2}\} \\ = (\lambda h)^n e^{-\lambda(t_n + h)} + o(h^n) = \lambda^n e^{-\lambda t_n} \cdot h^n + o(h^n). \end{aligned}$$

所以 (S_1, S_2, \dots, S_n) 的联合概率密度函数为:

$$g(t_1, t_2, \dots, t_n) = \begin{cases} \lambda^n e^{-\lambda t_n}, & 0 < t_1 < t_2 < \cdots < t_n, \\ 0, & \text{其它.} \end{cases} \quad (2.2.2)$$

第二步求 (X_1, X_2, \dots, X_n) 的联合概率密度. 注意到 $X_n = S_n - S_{n-1}$ ($n \geq 1$), 令 $x_n = t_n - t_{n-1}$, 则变换的雅可比行列式为

$$J = \frac{\partial(t_1, t_2, \dots, t_n)}{\partial(x_1, x_2, \dots, x_n)} = \begin{vmatrix} 1 & 0 & 0 & \cdots & 0 \\ 1 & 1 & 0 & \cdots & 0 \\ 1 & 1 & 1 & \cdots & 0 \\ \vdots & \vdots & \vdots & \ddots & \vdots \\ 1 & 1 & 1 & \cdots & 1 \end{vmatrix} = 1,$$

于是 (X_1, X_2, \dots, X_n) 的联合概率密度为

$$f(x_1, x_2, \dots, x_n) = \begin{cases} \lambda^n e^{-\lambda(x_1 + x_2 + \dots + x_n)}, & x_i \geq 0, 1 \leq i \leq n, \\ 0, & \text{其它.} \end{cases}$$

由上可得 X_k 的概率密度为 $f_k(x_k) = \lambda e^{-\lambda x_k}, x_k \geq 0, 1 \leq k \leq n$. 于是

$$f(x_1, x_2, \dots, x_n) = \prod_{k=1}^n f_k(x_k),$$

即证明了 $(X_k, 1 \leq k \leq n) (n \in \mathbb{N})$ 独立同指数分布. 必要性证毕.

下面证明充分性. 设 $\{X_k, k \geq 1\}$ 独立同指数分布. 令 $S_0 = 0, S_1 = X_1, \dots, S_n = \sum_{k=1}^n X_k$, 对 $\forall t > 0$, 定义

$$N(t) = \sup\{n : S_n \leq t, n = 0, 1, 2, \dots, \}.$$

由上定义可验证 $\{N(t), t \geq 0\}$ 是计数过程. 下面仍分三步证明它是 Poisson 过程.

第一步: 求 (S_1, S_2, \dots, S_n) 的联合概率密度及 $N(t)$ 的分布. 注意到证必要性第二部的逆过程仍成立, 即由 X_1, X_2, \dots, X_n 的联合概率密度

$$f(x_1, x_2, \dots, x_n) = \prod_{k=1}^n \lambda e^{-\lambda x_k}, \quad x_k \geq 0, 1 \leq k \leq n,$$

经 $S_1 = X_1, \dots, S_n = \sum_{k=1}^n X_k$, 可得 S_1, S_2, \dots, S_n 的联合概率密度为

$$g(t_1, t_2, \dots, t_n) = \begin{cases} \lambda^n e^{-\lambda t_n}, & 0 \leq t_1 \leq t_2 \leq \dots \leq t_n, \\ 0, & \text{其它.} \end{cases}$$

由上可得 S_n 的分布为

$$P(S_n \leq t) = 1 - e^{-\lambda t} \left(1 + \lambda t + \dots + \frac{(\lambda t)^{n-1}}{(n-1)!} \right).$$

故

$$P(N(t) = n) = P(S_n \leq t < S_{n+1}) = P(S_n \leq t) - P(S_{n+1} \leq t) = \frac{(\lambda t)^n}{n!} e^{-\lambda t}.$$

第二步: 证平稳性. 这里只写出对 $n \geq 1$ 的证明. 利用全概率公式, 有

$$\begin{aligned} P(N(s+t) - N(s) = n) &= \sum_{k=0}^{\infty} P(N(s) = k, N(s+t) = k+n) \\ &= \sum_{k=0}^{\infty} P(S_k \leq s < S_{k+1} < S_{k+n} \leq s+t < S_{k+n+1}) \\ &= P(s < S_1 \leq S_n \leq s+t < S_{n+1}) \\ &+ \sum_{k=1}^{\infty} \int_0^s P(S_k \leq s < S_k + X_{k+1} \leq S_k + \sum_{i=1}^n X_{k+i} \leq s+t < S_k + \sum_{i=1}^{n+1} X_{k+i} | S_k = u) dP(S_k \leq u) \\ &= P(s < S_1 \leq S_n \leq s+t < S_{n+1}) + \sum_{k=1}^{\infty} \int_0^s P(s-u < S_1 \leq S_n \leq s+t-u < S_{n+1}) dP(S_k \leq u) \end{aligned}$$

2.2 相邻事件的时间间隔, Poisson 过程与指数分布的关系

又

$$\begin{aligned}
 P(s < S_1 \leq S_n \leq s+t < S_{n+1}) &= \int_s^{s+t} P\left(\sum_{i=2}^n X_i \leq s+t-v < \sum_{i=2}^{n+1} X_i \mid X_1 = v\right) \lambda e^{-\lambda v} dv \\
 &= \int_s^{s+t} P(S_{n-1} \leq s+t-v < S_n) \lambda e^{-\lambda v} dv \\
 &= \int_s^{s+t} \frac{[\lambda(s+t-v)]^{n-1}}{(n-1)!} e^{-\lambda(s+t-v)} \lambda e^{-\lambda v} dv \\
 &= \frac{(\lambda t)^n}{n!} e^{-\lambda(s+t)}
 \end{aligned}$$

类似的 $P(s-u < S_1 \leq S_n \leq s+t-u < S_{n+1}) = \frac{(\lambda t)^n}{n!} e^{-\lambda(s+t-u)}$, 故

$$\begin{aligned}
 P(N(s+t) - N(s) = n) &= \frac{(\lambda t)^n}{n!} e^{-\lambda(s+t)} + \int_0^s \frac{(\lambda t)^n}{n!} e^{-\lambda(s+t-u)} \lambda du \\
 &= \frac{(\lambda t)^n}{n!} e^{-\lambda(s+t)} + \frac{(\lambda t)^n}{n!} e^{-\lambda(s+t)} (e^{\lambda s} - 1) \\
 &= \frac{(\lambda t)^n}{n!} e^{-\lambda t} \\
 &= P(N(t) = n)
 \end{aligned}$$

(注: 对 $n=0$ 情形类似证明, 留作读者练习)

第三步: 证增量独立性. 为突出方法, 这里仅证 $\forall s, t > 0, N(s)$ 与 $N(s+t) - N(s)$ 相互独立, 即证 $\forall n, m \geq 0$ 有

$$P(N(s) = m, N(s+t) - N(s) = n) = P(N(s) = m)P(N(s+t) - N(s) = n)$$

只写出 $m \geq 1$ 与 $n \geq 1$ 的情形, 其它可类似证之.

$$\begin{aligned}
 P(N(s) = m, N(s+t) - N(s) = n) &= P(S_m \leq s < S_{m+1} \leq S_{m+n} \leq s+t < S_{m+n+1}) \\
 &= \int_0^s P(s-u < X_{m+1} \leq \sum_{i=1}^n X_{m+i} \leq s+t-u \leq \sum_{i=1}^{n+1} X_{m+i} \mid S_m = u) dP(S_m \leq u) \\
 &= \int_0^s P(s-u \leq S_1 \leq S_n \leq s-u+t < S_{n+1}) dP(S_m \leq u) \\
 &= \int_0^s \frac{(\lambda t)^n}{n!} e^{-\lambda(s-u+t)} \lambda \frac{(\lambda u)^{m-1}}{(m-1)!} e^{-\lambda u} du \\
 &= \frac{(\lambda s)^m}{m!} e^{-\lambda s} \frac{(\lambda t)^n}{n!} e^{-\lambda t} \\
 &= P(N(s) = m)P(N(s+t) - N(s) = n)
 \end{aligned}$$

35

由 Poisson 过程的定义知, $\forall t_2 > t_1 \geq 0, N(t_2) - N(t_1) \geq 0$, 即 $N(t_2) \geq N(t_1)$, 说明 Poisson 过程的样本函数 $N(t)$ 是 t 的单调不减函数. 由 $(N(t) = n) = (S_n \leq t < S_{n+1})$ 知




图 2.2.1

$N(t)$ 是跳跃函数, 即当 $S_n \leq t < S_{n+1}$ 时 $N(t) = n$ 是一常数, 而仅在 $t = S_n, (n = 1, 2, \dots)$ 处跳跃, 且相邻的两次跳跃时间间隔 $\{X_n, n \geq 1\}$ 相互独立同指数分布 (参数为 $\lambda > 0$). 这就为 Poisson 过程的计算机模拟及其统计检验提供了理论基础与方法. Poisson 过程的样本函数如图 2.2.1 所示.


§ 2.3 剩余寿命与年龄

本节再从不同的角度刻画 Poisson 过程的若干重要特性.

设 $N(t)$ 表示在 $[0, t]$ 上事件发生的个数. S_n 表示第 n 个事件发生的时刻. 那么, $S_{N(t)}$ 表示在 t 时刻前最后一个事件发生的时刻, $S_{N(t)+1}$ 表示 t 时刻后首次事件发生的时刻. 注意这里 $S_{N(t)}$ 与 $S_{N(t)+1}$ 的下标 $N(t), N(t) + 1$ 是随机变量. 令

$$W(t) = S_{N(t)+1} - t,$$

$$V(t) = t - S_{N(t)}.$$



$W(t)$ 与 $V(t)$ 如上图所示. 为了解释 $W(t)$ 与 $V(t)$ 的具体意义, 设一零件在 $t = 0$ 时开始工作, 若它失效, 立即更换 (设更换所需的时间为零). 一个新零件重又开始工作, 如此重复下去, 记 S_n 为第 n 次更换时刻, 则 $X_n = S_n - S_{n-1}$ 表示第 n 个零件的工作寿命. 于是 $W(t)$ 表示观察者在时刻 t 所观察的正在工作的零件的剩余寿命; $V(t)$ 表示正在工作的零件的工作时间, 称为年龄. 还可以有别的解释: 若 S_n 表示第 n 辆汽车到站的时刻, 某一乘客到达该站的时刻为 t , 则 $W(t)$ 表示该乘客等待上车的等待时间. 若 S_n 表示某地第 n 次发生地震的时刻, 则 $S_{N(t)+1}$ 表示 t 时刻以后直到首次地震的时刻, $W(t)$ 表示 t 时刻后直到首次地震之间的剩余时间, 等等. 故称 $W(t)$ 为 **剩余寿命** 或 **剩余**

2.3 剩余寿命与年龄

时间；称 $V(t)$ 为 **年龄**. 显然，研究 $W(t), V(t)$ 的特性及它们的关系很有意义.

由定义知 $\forall t \geq 0, W(t) \geq 0, 0 \leq V(t) \leq t$.

定理 2.3.1 设 $\{N(t), t \geq 0\}$ 是参数为 λ 的 Poisson 过程，则：

1° $W(t)$ 与 $(X_n, n \geq 1)$ 同分布，即

$$P(W(t) \leq x) = 1 - \exp(-\lambda x), \quad x \geq 0. \quad (2.3.1)$$

2° $V(t)$ 是“截尾”的指数分布，即

$$P(V(t) \leq x) = \begin{cases} 1 - \exp(-\lambda x), & 0 \leq x < t, \\ 1, & t \leq x. \end{cases} \quad (2.3.2)$$

证： 由

$$\{W(t) > x\} = \{N(t+x) - N(t) = 0\}.$$

及

$$\{V(t) > x\} = \begin{cases} \{N(t) - N(t-x) = 0\}, & t > x, \\ \emptyset, & t \leq x. \end{cases}$$

即得所要结论. □

定理 2.3.2 若非负 $r.v. X_n (n \geq 1)$ 独立同分布 $F(x)$ ，则对 $\forall x \geq 0, t \geq 0$

$$P(W(t) > x) = 1 - F(x+t) + \int_0^t P(W(t-u) > x) dF(u) \quad (2.3.3)$$

证： 由条件数学期望

$$P(W(t) > x) = \int_0^{+\infty} P(W(t) > x | X_1 = s) dF(s) \quad (*)$$

下面讨论 $P(W(t) > x | X_1 = s)$ ，由 $W(t)$ 定义

(1) 当 $s > t+x$ 时， $P(W(t) > x | X_1 = s) = 1$;

(2) 当 $t \leq s < s+t$ 时， $P(W(t) > x | X_1 = s) = 0$;

(3) 当 $s < t$ 时, 由 $X_n (n \geq 1)$ i.i.d. 得

$$\begin{aligned}
 P(W(t) > x | X_1 = s) &= P(S_{N(t)+1} - t > x | X_1 = s) \\
 &= P\left(\sum_{j=2}^{N(t)+1} X_j - (t-s) > x | X_1 = s\right) \\
 &= \sum_{m=1}^{\infty} P\left(\sum_{j=2}^{m+1} X_j - (t-s) > x, N(t) = m | X_1 = s\right) \\
 &= \sum_{m=1}^{\infty} P\left(\sum_{j=2}^{m+1} X_j - (t-s) > x, S_m \leq t < S_{m+1} | X_1 = s\right) \\
 &= \sum_{m=1}^{\infty} P\left(\sum_{j=2}^{m+1} X_j - (t-s) > x, \sum_{j=2}^m X_j \leq t-s < \sum_{j=2}^{m+1} X_j | X_1 = s\right) \\
 &= \sum_{m=1}^{\infty} P\left(\sum_{j=2}^{m+1} X_j - (t-s) > x, \sum_{j=2}^m X_j \leq t-s < \sum_{j=2}^{m+1} X_j\right) \\
 &= \sum_{m=1}^{\infty} P(S_m - (t-s) > x, S_{m-1} \leq t-s < S_m) \\
 &= \sum_{m=1}^{\infty} P(S_m - (t-s) > x, N(t-s) = m-1) \\
 &= P(S_{N(t-s)} - (t-s) > x) \\
 &= P(W(t-s) > x)
 \end{aligned}$$

由 (1), (2), (3) 即得 (2.3.3). □

我们可以用 $W(t)$ 与 X_n 的关系来刻画 Poisson 过程.

定理 2.3.3 若对 $\forall t \geq 0, W(t)$ 与 $X_n (n \geq 1)$ 同分布 $F(x)$, 且 $F(0) = 0$, 则 $\{N(t), t \geq 0\}$ 为 Poisson 过程.

证: 令 $G(x) = 1 - F(x) = P(W(t) > x)$, 由式 (2.3.3) 及 $F(0) = 0$ 得, 对 $\forall x \geq 0, t \geq 0$, 有

$$G(x+t) = G(x)G(t) \quad (2.3.4)$$

因为 $F(x)$ 是单调不减, 右连续函数. 所以 $G(x)$ 是单调不增, 右连续函数. 则对 (2.3.4) 两端对 x 求导, 得 $G'_x(x+t) = G'_x(x)G(t)$. 又 $G'_x(x+t) = G'_t(x+t)$ 所以

$$G'_t(x+t) = G'_x(x)G(t)$$

令 $x = 0$, 则 $G'_t(t) = G'_x(0)G(t)$.

令 $\lambda = -G'_x(0)$. 由于 $G(x)$ 单调不增, 所以 $\lambda \geq 0$; 又因 $F(x)$ 为分布函数, 不可能为常数, 从而 $\lambda \neq 0$; 再由 $G(0) = 1 - F(0) = 1$, 得

$$G(t) = e^{-\lambda t}$$

2.4 到达时间的条件分布

即

$$F(x) = P(X_n \leq x) = 1 - e^{-\lambda x} \quad (x \geq 0)$$

再由定理 2.2.1 知 $\{N(t), t \geq 0\}$ 是 Poisson 过程. □

该定理最早在 1972 年由 K.L.Chung 得到. 说明 $W(t)$ 与 $X_n (n \geq 1)$ 同指数分布, 是 Poisson 过程特有的性质. 本定理可应用于检验 $\{N(t), t \geq 0\}$ 是否为 Poisson 过程.

类似地, 可以用 $E[W(t)]$ 与 t 无关或 $(W(t), V(t))$ 的联合分布来刻画 Poisson 过程.

§ 2.4 到达时间的条件分布

本节讨论在给定 $N(t) = n$ 条件下, S_1, S_2, \dots, S_n 的条件分布, 有关性质及其应用. 先看下面定理:

定理 2.4.1 设 $\{N(t), t \geq 0\}$ 是 Poisson 过程, 则对 $\forall 0 < s < t$,

$$P(X_1 \leq s | N(t) = 1) = \frac{s}{t}. \quad (2.4.1)$$

证:

$$\begin{aligned} P(X_1 \leq s | N(t) = 1) &= \frac{P(X_1 \leq s, N(t) = 1)}{P(N(t) = 1)} = \frac{P(N(s) = 1, N(t) - N(s) = 0)}{P(N(t) = 1)} \\ &= \frac{(\lambda s)e^{-\lambda s} \cdot e^{-\lambda(t-s)}}{(\lambda t)e^{-\lambda t}} = \frac{s}{t}. \quad \square \end{aligned}$$

这定理说明, 由于 Poisson 过程具有平稳独立增量性, 从而在已知 $[0, t]$ 上有一事件发生的条件下, 事件发生的时间 X_1 在 $[0, t]$ 上是“等可能性的”, 即它的条件分布是 $[0, t]$ 上的均匀分布. 自然, 我们要问: (1) 这个性质是否可推广到 $N(t) = n, n \geq 1$ 的情形? (2) 这个性质是否是 Poisson 过程特有的? 换句话说: 本定理的逆命题是否成立? 为回答 (1), 先讨论顺序统计量的性质.

设 Y_1, Y_2, \dots, Y_n 是独立同分布, 非负的随机变量, 密度函数为 $f(y)$, 记 $Y_{(1)} \leq Y_{(2)} \leq \dots \leq Y_{(n)}$ 为相应的顺序统计量, 容易看到, 对 $\forall 0 < y_1 < y_2 < \dots < y_n$, 取充分小 $h > 0$, 使

$$0 < y_1 < y_1 + h < y_2 < y_2 + h < y_3 < \dots < y_{n-1} + h < y_n < y_n + h,$$

则

$$\begin{aligned} &\{y_1 < Y_{(1)} \leq y_1 + h, y_2 < Y_{(2)} \leq y_2 + h, \dots, y_n < Y_{(n)} \leq y_n + h\} \\ &= \bigcup_{(i_1, i_2, \dots, i_n)} \{y_1 < Y_{i_1} \leq y_1 + h, y_2 < Y_{i_2} \leq y_2 + h, \dots, y_n < Y_{i_n} \leq y_n + h\} \end{aligned}$$

等式右边各事件互不相容, 得

$$\begin{aligned} & \lim_{h \rightarrow 0} P(y_1 < Y_{(1)} \leq y_1 + h, y_2 < Y_{(2)} \leq y_2 + h, \dots, y_n < Y_{(n)} \leq y_n + h) / h^n \\ &= \lim_{h \rightarrow 0} n! P(y_1 < Y_{i_1} \leq y_1 + h, y_2 < Y_{i_2} \leq y_2 + h, \dots, y_n < Y_{i_n} \leq y_n + h) / h^n \end{aligned}$$

由此可知顺序统计量 $Y_{(1)}, Y_{(2)}, \dots, Y_{(n)}$ 的联合概率密度为

$$f(y_1, y_2, \dots, y_n) = \begin{cases} n! \prod_{i=1}^n f(y_i), & 0 < y_1 < y_2 < \dots < y_n, \\ 0, & \text{其它.} \end{cases}$$

若 $\{Y_i, 1 \leq i \leq n\}$ 在 $[0, t]$ 上独立同均匀分布, 则其顺序统计量 $Y_{(1)}, \dots, Y_{(n)}$ 的 j.p.d.f. 为

$$f(y_1, y_2, \dots, y_n) = \begin{cases} \frac{n!}{t^n}, & 0 < y_1 < y_2 < \dots < y_n \leq t, \\ 0, & \text{其它.} \end{cases}$$

对问题 (1), 有以下有用的定理:

定理 2.4.2 设 $\{N(t), t \geq 0\}$ 为 Poisson 过程, 则事件相继发生的时间 S_1, S_2, \dots, S_n 在已给 $N(t) = n$ 下的条件概率密度为

$$f(t_1, t_2, \dots, t_n) = \begin{cases} \frac{n!}{t^n}, & 0 < t_1 < t_2 < \dots < t_n \leq t, \\ 0, & \text{其它.} \end{cases} \quad (2.4.2)$$

证: 对 $\forall 0 = t_0 < t_1 < t_2 < \dots < t_n < t_{n+1} = t$, 取 $h_0 = h_{n+1} = 0$ 及充分小的 h_i , 使 $t_i + h_i < t_{i+1}, 1 \leq i \leq n$, 则:

$$\begin{aligned} & P(t_i < S_i \leq t_i + h_i, 1 \leq i \leq n | N(t) = n) \\ &= \frac{P(N(t_i + h_i) - N(t_i) = 1, 1 \leq i \leq n, N(t_{j+1}) - N(t_j + h_j) = 0, 1 \leq j \leq n)}{P(N(t) = n)} \\ &= \frac{(\lambda h_1) e^{-\lambda h_1} \dots (\lambda h_n) e^{-\lambda h_n} \cdot e^{-\lambda(t - h_1 - h_2 - \dots - h_n)}}{\frac{(\lambda t)^n}{n!} e^{-\lambda t}} = \frac{n!}{t^n} h_1 h_2 \dots h_n, \end{aligned}$$

因此

$$\frac{P(t_i < S_i \leq t_i + h_i, 1 \leq i \leq n | N(t) = n)}{h_1 h_2 \dots h_n} = \frac{n!}{t^n},$$

所以

$$f(t_1, t_2, \dots, t_n) = \begin{cases} \frac{n!}{t^n}, & 0 < t_1 < t_2 < \dots < t_n \leq t, \\ 0, & \text{其它.} \end{cases} \quad \square$$

本定理说明在 $N(t) = n$ 条件下 S_1, S_2, \dots, S_n 的条件分布函数与 n 个在 $[0, t]$ 上相互独立同均匀分布的顺序统计量的分布函数相同.

对问题 (2), 即逆命题, 有以下定理:

2.4 到达时间的条件分布

定理 2.4.3 设 $\{N(t), t \geq 0\}$ 为计数过程, X_n 为第 n 个事件与第 $n-1$ 个事件的时间间隔, $\{X_n, n \geq 1\}$ 独立同分布 $F(x) = P(X_n \leq x)$, 若 $F(0) = 0$, 且对 $\forall 0 \leq s \leq t$, 有

$$P(X_1 \leq s | N(t) = 1) = \frac{s}{t} \quad (0 < t),$$

则 $\{N(t), t \geq 0\}$ 为 Poisson 过程.

证: 由题意: $P(X_1 \leq s | N(s+x) = 1) = \frac{s}{s+x}$, $P(X_1 \leq x | N(s+x) = 1) = \frac{x}{s+x}$; 所以

$$P(X_1 \leq s | N(s+x) = 1) + P(X_1 \leq x | N(s+x) = 1) = 1 \quad (2.4.3)$$

又

$$P(X_1 \geq s | N(s+x) = 1) = \frac{P(X_1 \leq s, X_1 \leq s+x < X_1 + X_2)}{P(X_1 \leq s+x < X_1 + X_2)}$$

利用全概率公式, 得

$$\begin{aligned} P(X_1 \leq s, X_1 \leq s+x < X_1 + X_2) &= \int_0^s (1 - F(s+x-u))dF(u) \\ P(X_1 \leq s+x < X_1 + X_2) &= \int_0^{s+x} (1 - F(s+x-u))dF(u) \end{aligned}$$

由 (2.4.3) 得:

$$\int_0^x (1 - F(s+x-u))dF(u) + \int_0^s (1 - F(s+x-u))dF(u) = \int_0^{s+x} (1 - F(s+x-u))dF(u)$$

所以

$$\int_0^s (1 - F(s+x-u))dF(u) = \int_x^{s+x} (1 - F(s+x-u))dF(u)$$

化简上式, 得 $F(s) + F(x) - F(s)F(x) = F(x+s)$.

所以 $(1 - (F(x+s))) = (1 - F(s))(1 - F(x))$, 令 $G(x) = 1 - F(x)$, 则

$$G(x+s) = G(x)G(s)$$

类似于定理 2.3.3 证明中 (2.3.4) 式以后的证明部分, 即得结论. □

定理 2.4.4 设 $\{N(t), t \geq 0\}$ 为计数过程, $\{X_n, n \geq 1\}$ 为相继事件发生的时间间隔, 独立同分布, $F(x) = P(X_n \leq x)$, 若 $EX_n < \infty$, $F(0) = 0$, 且对 $\forall n \geq 1, 0 \leq s \leq t$, 有

$$P(S_n \leq s | N(t) = n) = \left(\frac{s}{t}\right)^n \quad (0 < t),$$

则 $\{N(t), t \geq 0\}$ 为 Poisson 过程.

证明从略.

注: 利用以上结果, 检验 Poisson 过程时不需要知道参数 λ .

二个例子:

例 1. 设到达火车站的顾客流遵照参数为 λ 的 Poisson 流 $\{N(t), t \geq 0\}$, 火车 t 时刻离开车站, 求在 $[0, t]$ 到达车站的顾客等待时间总和的期望值.

解: 设第 i 个顾客到达火车站的时刻为 S_i , 则 $[0, t]$ 到达车站的顾客等待时间总和为

$$S(t) = \sum_{i=1}^{N(t)} (t - S_i).$$

因

$$\begin{aligned} E(S(t) | N(t) = n) &= E\left\{\sum_{i=1}^{N(t)} (t - S_i) \middle| N(t) = n\right\} \\ &= E\left[\sum_{i=1}^n (t - S_i) \middle| N(t) = n\right] = nt - E\left[\sum_{i=1}^n S_i \middle| N(t) = n\right], \end{aligned}$$

仍记 $\{Y_i, 1 \leq i \leq n\}$ 为 $[0, t]$ 上独立同均匀分布的 r.v., 则

$$\begin{aligned} E\left\{\sum_{i=1}^n S_i \middle| N(t) = n\right\} &= E\left(\sum_{i=1}^n Y_{(i)}\right) \quad (\text{由定理 2.4.2}) \\ &= E\left(\sum_{i=1}^n Y_i\right) = \frac{nt}{2}. \end{aligned}$$

故

$$E\left\{\sum_{i=1}^n (t - S_i) \middle| N(t) = n\right\} = \frac{nt}{2}.$$

所以

$$\begin{aligned} E[S(t)] &= \sum_{n=0}^{\infty} \left(P\{N(t) = n\} E\left[\sum_{i=1}^{N(t)} (t - S_i) \middle| N(t) = n\right] \right) \\ &= \sum_{n=0}^{\infty} P(N(t) = n) \cdot \frac{nt}{2} = \frac{t}{2} \cdot E(N(t)) = \frac{\lambda}{2} t^2. \quad \square \end{aligned}$$

例 2. 设一系统在 $[0, t]$ 内承受的冲击数 $\{N(t), t \geq 0\}$ 是参数为 λ 的 Poisson 流. 第 i 次冲击受的损失为 D_i , 设 $\{D_i, i \geq 1\}$ 独立同分布, 与 $\{N(t), t \geq 0\}$ 独立. 且损失随时间按负指数衰减, 即 $t = 0$ 时损失为 D , 在 t 时损失为 $De^{-\alpha t}, \alpha > 0$. 设损失是可加的, 那么在 t 时刻的损失之和为

$$\xi(t) = \sum_{i=1}^{N(t)} D_i e^{-\alpha(t-S_i)},$$

其中 S_i 为第 i 次冲击到达的时刻. 试求 $E\xi(t)$.

2.4 到达时间的条件分布

解：先求条件期望，

$$\begin{aligned} E\{\xi(t) | N(t) = n\} &= E\left[\sum_{i=1}^{N(t)} D_i e^{-\alpha(t-S_i)} | N(t) = n\right] = E\left[\sum_{i=1}^n D_i e^{-\alpha(t-S_i)} | N(t) = n\right] \\ &= \sum_{i=1}^n E[D_i | N(t) = n] \cdot E[e^{-\alpha(t-S_i)} | N(t) = n] \\ &= ED \cdot e^{-\alpha t} \sum_{i=1}^n E[e^{\alpha S_i} | N(t) = n]. \end{aligned}$$

记 Y_1, Y_2, \dots, Y_n 为 $[0, t]$ 上独立同均匀分布的 r.v., 则由定理 2.4.2, 有

$$\begin{aligned} E\left\{\sum_{i=1}^n \exp(\alpha S_i) | N(t) = n\right\} &= E\left\{\sum_{i=1}^n \exp(\alpha Y_{(i)})\right\} = E\left\{\sum_{i=1}^n \exp(\alpha Y_i)\right\} \\ &= n \cdot \int_0^t \exp(\alpha x) \cdot \frac{dx}{t} = \frac{n}{\alpha t} [\exp(\alpha t) - 1]. \end{aligned}$$

所以

$$E(\xi(t) | N(t) = n) = \frac{n}{\alpha t} [1 - \exp(-\alpha t)] \cdot ED.$$

即

$$E(\xi(t) | N(t)) = \frac{N(t)}{\alpha t} [1 - \exp(-\alpha t)] ED.$$

故

$$E\{\xi(t)\} = E[E(\xi(t) | N(t))] = \frac{\lambda ED}{\alpha} [1 - \exp(-\alpha t)]. \quad \square$$

关于到达时刻，我们有以下有用的定理：

定理 2.4.5 设 $\{N(t), t \geq 0\}$ 是参数为 λ 的 Poisson 过程， $S_k, k \geq 1$ 为其到达时刻，则对任意的 $[0, \infty)$ 上的可积函数 f 有

$$E\left[\sum_{n=1}^{\infty} f(S_n)\right] = \lambda \int_0^{\infty} f(t) dt. \quad (2.4.4)$$

证：由 (2.2.1)，当 $t \geq 0$ 时， $S_n = \inf\{t : N(t) = n\}$ ， $\{S_n \leq t\} = \{N(t) \geq n\}$ 可得

$$P(S_n \leq t) = P(N(t) \geq n) = \sum_{j=n}^{\infty} \frac{(\lambda t)^j}{j!} e^{-\lambda t},$$

因此 S_n 的概率密度为：

$$f_{s_n}(t) = \sum_{j=n}^{\infty} \left[\lambda \frac{(\lambda t)^{j-1}}{(j-1)!} e^{-\lambda t} - \lambda \frac{(\lambda t)^j}{j!} e^{-\lambda t} \right] = \lambda \frac{(\lambda t)^{j-1}}{(j-1)!} e^{-\lambda t} I_{(t \geq 0)}.$$

若设 f 非负，由上式得

$$\begin{aligned} E[f(S_n)] &= \lambda \int_0^{\infty} f(t) \frac{(\lambda t)^{n-1}}{(n-1)!} e^{-\lambda t} dt, \\ \sum_{n=1}^{\infty} E[f(S_n)] &= \lambda \int_0^{\infty} f(t) \sum_{n=1}^{\infty} \frac{(\lambda t)^{n-1}}{(n-1)!} e^{-\lambda t} dt = \lambda \int_0^{\infty} f(t) dt. \end{aligned}$$

对一般的 f , 将已证结果用于 $f^+ = \max(f, 0)$ 及 $f^- = \max(-f, 0)$, 即可知 (2.4.4) 式对 $f = f^+ - f^-$ 成立. \square

下面我们利用定理 2.4.5 提供上面例 2 结果的另一种求解方法. 若取

$$f(s) = I_{[0,t]}(s)e^{-\alpha(t-s)},$$

则

$$\xi(t) = \sum_{i=1}^{N(t)} D_i e^{-\alpha(t-S_i)} = \sum_{i=1}^{\infty} I_{\{S_i \leq t\}} D_i e^{-\alpha(t-S_i)} = \sum_{i=1}^{\infty} D_i f(S_i),$$

于是

$$\begin{aligned} E[\xi(t)] &= \sum_{i=1}^{\infty} E[D_i f(S_i)] = E[D] E\left[\sum_{i=1}^{\infty} f(S_i)\right] \\ &= E[D] \lambda \int_0^{\infty} f(s) ds = E[D] \lambda \int_0^t e^{-\alpha(t-s)} ds = \frac{\lambda E[D]}{\alpha} [1 - e^{-\alpha t}]. \end{aligned}$$

§ 2.5 Poisson 过程的模拟, 检验及参数估计

1. 模拟

由前面讨论知, Poisson 过程的样本轨道是单调不减的跳跃函数, 相邻两次的跳跃间隔 $X_n (n \geq 1)$ 独立同指数分布 (参数 $\lambda > 0$). 因此, Poisson 过程的样本函数可用下述步骤模拟:

(1) 产生 $[0, 1]$ 上均匀分布且相互独立的一串随机数, 记为 $\{U_n, n \geq 1\}$, 这在计算机上是能够实现的.

(2) 令 $X_k = -\lambda^{-1} \ln U_k$ (λ 为已给参数), 易证 $\{X_n, n \geq 1\}$ 是独立同指数分布随机变量. 并设 $S_0 = 0, S_n = \sum_{k=1}^n X_k$.

(3) 定义 $N(t)$ 如下: $N(t) = 0$, 如 $0 \leq t < S_1, \dots, N(t) = n$, 如 $S_n \leq t < S_{n+1}, \dots$. 如此继续下去, 就得到 $\{N(t), t \geq 0\}$ 的一条轨道.

2. 检验

按照 Poisson 过程性质, 要检验 $\{N(t), t \geq 0\}$ 是否是 Poisson 过程, 可转化为下面检验问题之一:

- (1) 检验 $\{X_n, n \geq 1\}$ 是否独立同指数分布;
- (2) $\forall t > 0$, 检验 $W(t)$ 与 $X_n (n \geq 1)$ 是否同分布;

2.5 Poisson 过程的模拟, 检验及参数估计

(3) $\forall t > 0$, 检验在 $N(t) = 1$ 下 $S_1 = X_1$ 是否是 $[0, t]$ 上的均匀分布;

(4) 给定 $T > 0$, 检验在 $N(T) = n$ 下 S_1, S_2, \dots, S_n 的条件分布是否与 $[0, T]$ 上 n 个独立均匀分布的顺序统计量的分布相同.

这里仅讨论最后一种的具体检验方法.

提出统计假设 $H_0: \{N(t), t \geq 0\}$ 是 Poisson 过程. 令 $\sigma_n = \sum_{k=1}^n S_k$. 当 H_0 成立, 由定理 2.4.2

$$E\{\sigma_n | N(T) = n\} = E\left\{\sum_{i=1}^n y_{(i)}\right\} = E\left\{\sum_{i=1}^n y_i\right\} = \frac{nT}{2},$$
$$D\{\sigma_n | N(T) = n\} = D\left\{\sum_{i=1}^n y_{(i)}\right\} = D\left\{\sum_{i=1}^n y_i\right\} = \frac{nT^2}{12}.$$

其中 $\{Y_i, 1 \leq i \leq n\}$ i.i.d. $Y_i \sim U[0, t]$. $Y_{(1)}, Y_{(2)}, \dots, Y_{(i)}, \dots, Y_{(n)}$ 为其顺序统计量.

$$\lim_{n \rightarrow \infty} P\left\{\frac{\sigma_n - \frac{n}{2}T}{T\sqrt{\frac{n}{12}}} \leq x | N(T) = n\right\} = \lim_{n \rightarrow \infty} P\left(\frac{\sum_{i=1}^n Y_i - \frac{n}{2}T}{\frac{nT^2}{12}} \leq x\right) = \Phi(x) = \frac{1}{\sqrt{2\pi}} \int_{-\infty}^x e^{-\frac{u^2}{2}} du$$

即对充分大的 n , 有

$$P\left(\frac{\sigma_n}{T} \leq \frac{1}{2}\left[n + x\left(\frac{n}{3}\right)^{\frac{1}{2}}\right] | N(T) = n\right) \approx \Phi(x).$$

若给定置信水平 $\alpha = 0.05$, 则当

$$\frac{\sigma_n}{T} \in \frac{1}{2}\left[n \pm 1.96\left(\frac{n}{3}\right)^{\frac{1}{2}}\right]$$

时, 接受 H_0 , 否则, 拒绝 H_0 . 此法优点在于不要求已知 λ .

3. 参数 λ 的估计

经上述检验后, 如接受 H_0 , 则认为 $\{N(t), t \geq 0\}$ 为 Poisson 过程, 进而要求: 由已有数据如何估计参数 λ ?

(1) 极大似然估计

设 $\{N(t), t \geq 0\}$ 为 Poisson 过程, 给定 T , 若在 $[0, T]$ 上观察到 S_1, S_2, \dots, S_n 的取值 $t_1, t_2, \dots, t_n \leq T$, 则似然函数为

$$L(t_1, t_2, \dots, t_n, \lambda) = \lambda^n e^{-\lambda T}.$$

令 $\frac{dL}{d\lambda} = 0$, 即得 λ 的极大似然估计为

$$\hat{\lambda} = \frac{n}{T}.$$

注意: 给定 T 后, 则落在 $[0, T]$ 上的个数 n 是随观察结果而定的.

(2) 区间估计

仅讨论固定 n 的情形. 若 $\{N(t), t \geq 0\}$ 是 Poisson 过程, 则由定理 2.2.1, $S_n = \sum_{k=1}^n X_k$ 的概率密度函数为:

$$f_n(t) = \frac{\lambda(\lambda t)^{n-1}}{(n-1)!} e^{-\lambda t} = \frac{\lambda^n}{\Gamma(n)} t^{n-1} e^{-\lambda t}, \quad (t \geq 0),$$

其中 $\Gamma(\alpha) = \int_0^\infty x^{\alpha-1} e^{-x} dx$ 为 Γ 函数, $\Gamma(n) = (n-1)!$. 因此, $2\lambda S_n$ 的概率密度函数为

$$g_n(t) = \frac{1}{2^{\frac{2n}{2}} \Gamma(\frac{2n}{2})} t^{\frac{2n}{2}-1} e^{-\frac{t}{2}} \quad (t \geq 0),$$

这与 $\chi^2(2n)$ 的密度相同, 故 $2\lambda S_n = \chi^2(2n)$. 取置信度 $1 - \alpha$, 则

$$P\left(\chi_{\alpha/2}^2(2n) \leq 2\lambda S_n \leq \chi_{1-\frac{\alpha}{2}}^2(2n)\right) = 1 - \alpha.$$

故置信度为 $1 - \alpha$ 的 λ 的区间估计为

$$\left[\frac{\chi_{\alpha/2}^2(2n)}{2S_n}, \frac{\chi_{1-\frac{\alpha}{2}}^2(2n)}{2S_n} \right].$$

S_n 由数据得到, $\chi_{\alpha/2}^2(2n)$ 及 $\chi_{1-\frac{\alpha}{2}}^2(2n)$ 查表得到.

Poisson 过程的几种推广.

在前几节讨论中, 我们看到 Poisson 过程有许多独特的性质. 这与它的定义中加了许多严格限制有关. 许多实际问题中并不都满足这些条件. 因此, 有必要讨论定义中某些条件放宽后的情形, 这就是它的若干推广情形.

§ 2.6 非时齐 Poisson 过程

先看放宽 § 2.1 定义中平稳性即 λ 是常数的限制.

定义 一计数过程 $\{N(t), t \geq 0\}$, 称它为具有强度函数 $\{\lambda(t) > 0, t \geq 0\}$ 的 **非时齐 Poisson 过程**, 若满足:

- 1° $N(0) = 0$;
- 2° $\{N(t), t \geq 0\}$ 是一独立增量过程;
- 3° 对充分小的 $h > 0$, 有

$$P(N(t+h) - N(t) = 1) = \lambda(t)h + o(h),$$

$$P(N(t+h) - N(t) \geq 2) = o(h).$$

如令 $m(t) = \int_0^t \lambda(s) ds$, 其中 $\lambda(t) \geq 0$, 则有以下:

2.7 复合 Poisson 过程

定理 2.6.1 若 $\{N(t), t \geq 0\}$ 是非时齐具有强度函数 $\{\lambda(t), t \geq 0\}$ 的 Poisson 过程, 则 $\forall s, t \geq 0$,

$$P(N(s+t) - N(s) = n) = \frac{[m(s+t) - m(s)]^n}{n!} \exp\{-[m(s+t) - m(s)]\} \quad (n \geq 0). \quad (2.6.1)$$

该定理的证明与定理 2.1.1 的证明类似, 留给读者作为练习.

我们把 § 2.1 定义的过程称为时齐 (homogeneous) Poisson 过程. 显然, 在定理 2.6.1 中, 如令 $\lambda(s) = \lambda$ 即为定理 2.1.1. 事实上, 非时齐 Poisson 过程与时齐 Poisson 过程也可通过变换, 互相转化.

定理 2.6.2

1° 设 $\{N(t), t \geq 0\}$ 是具有强度函数 $\{\lambda(s) > 0, s \geq 0\}$ 的非时齐 Poisson 过程. 令 $m(t) = \int_0^t \lambda(s) ds$, $m^{-1}(t)$ 是 $m(t)$ 的反函数, 即

$$m^{-1}(u) = \inf\{t : t > 0, m(t) \geq u, u \geq 0\},$$

记 $M(u) = N(m^{-1}(u))$, 则 $\{M(u), u \geq 0\}$ 是时齐 Poisson 过程.

2° 设 $\{M(u), u \geq 0\}$ 是时齐 Poisson 过程, 参数 $\lambda = 1$. 若给定强度函数 $\{\lambda(s) \geq 0, s \geq 0\}$, 令 $m(t) = \int_0^t \lambda(s) ds$, $N(t) = M(m(t))$, 则 $\{N(t), t \geq 0\}$ 是非时齐的具有强度函数 $\{\lambda(s), s \geq 0\}$ 的 Poisson 过程.

证明留给读者作为练习.

§ 2.7 复合 Poisson 过程

定义 设 $\{Y_i, i \geq 1\}$ 是独立与 Y 同分布的随机变量序列, $\{N(t), t \geq 0\}$ 为 Poisson 过程, 且 $\{N(t), t \geq 0\}$ 与 $\{Y_i, i \geq 1\}$ 独立, 记

$$X(t) = \sum_{i=1}^{N(t)} Y_i,$$

称 $\{X(t), t \geq 0\}$ 为 **复合 Poisson 过程** (Compound Poisson Process).

如 $\{N(t), t \geq 0\}$ 表示粒子流, $N(t)$ 表示 $[0, t]$ 到达的粒子数, Y_i 表示第 i 个到达粒子的能量, 则 $X(t)$ 表示 $[0, t]$ 内到达粒子的总能量. 若 $\{N(t), t \geq 0\}$ 表示一顾客流, Y_i 表示第 i 个顾客的行李重量, 则 $\{X(t), t \geq 0\}$ 表示 $[0, t]$ 内到达的顾客行李总重量, 等等.

为求 $X(t)$ 的矩, 先求它的矩母函数:

$$\begin{aligned}\phi_t(u) &= E[\exp\{uX(t)\}] = \sum_{n=0}^{\infty} P\{N(t) = n\} E[\exp\{uX(t)\} | N(t) = n] \\ &= \sum_{n=0}^{\infty} \frac{(\lambda t)^n}{n!} e^{-\lambda t} E[\exp\{u(Y_1 + Y_2 + \cdots + Y_n)\} | N(t) = n] \\ &= \sum_{n=0}^{\infty} \frac{(\lambda t)^n}{n!} e^{-\lambda t} E[\exp\{u(Y_1 + Y_2 + \cdots + Y_n)\}] = \sum_{n=0}^{\infty} \frac{(\lambda t)^n}{n!} e^{-\lambda t} \left(E[\exp\{uY_1\}]\right)^n.\end{aligned}$$

令 $\phi_Y(u) = E\{\exp(uY)\}$ 为 Y 的矩母函数, 则

$$\phi_t(u) = \sum_{n=0}^{\infty} \frac{(\lambda t \phi_Y(u))^n}{n!} e^{-\lambda t} = \exp\{\lambda t(\phi_Y(u) - 1)\}. \quad (2.7.1)$$

对上式在 $u = 0$ 求导, 得

$$E\{X(t)\} = \phi'_t(0) = \lambda t \cdot EY, \quad (2.7.2)$$

及

$$D\{X(t)\} = \lambda t E(Y^2). \quad (2.7.3)$$

特殊情况: 若 $\{\rho_i, i \geq 1\}$ 为独立同分布, 取值为正整数的随机变量序列, 且与 Poisson 过程 $\{N(t), t \geq 0\}$ 独立, 记

$$X(t) = \sum_{i=1}^{N(t)} \rho_i,$$

则称 $\{X(t), t \geq 0\}$ 为平稳无后效流.

容易理解, $X(t)$ 可描述成批到达的“顾客流”, 即每次同时到达的顾客数是随机的. 它在排队系统中大有用处.

§ 2.8 条件 Poisson 过程

把参数 λ 推广为一正的随机变量的情形, 即下面所述的条件 Poisson 过程.

定义 设 Λ 是一正的随机变量, 分布函数为 $G(x), x \geq 0$, 设 $\{N(t), t \geq 0\}$ 是一计数过程, 且当给定 $\Lambda = \lambda$ 条件下, $\{N(t), t \geq 0\}$ 是一 Poisson 过程, 即 $\forall s, t \geq 0, n \in \mathbb{N}_0 = \{0, 1, 2, \cdots\}, \lambda \geq 0$,

$$P\{N(s+t) - N(s) = n | \Lambda = \lambda\} = \frac{(\lambda t)^n}{n!} e^{-\lambda t}, \quad (2.8.1)$$

称 $\{N(t), t \geq 0\}$ 是 **条件 Poisson 过程**.

注: 这里 $\{N(t), t \geq 0\}$ 不是增量独立的过程. 由全概率公式, 可得

$$P\{N(s+t) - N(s) = n\} = \int_0^{\infty} e^{-\lambda t} \frac{(\lambda t)^n}{n!} dG(\lambda). \quad (2.8.2)$$

§ 2.9 更新过程

由定理 2.4.3 知, 一个计数过程, 若它们相邻事件到达的时间间隔 X_n 是指数分布, 则此过程为 Poisson 流. 现在, 我们来考虑 X_n 是一般分布时的情形, 这便是更新过程.

定义 设 $\{X_k, k \geq 1\}$ 是独立同分布, 取值非负的随机变量, 分布函数为 $F(x), x \geq 0$, 且 $F(0) < 1$, 令 $S_0 = 0, S_n = \sum_{k=1}^n X_k$, 对 $\forall t \geq 0$, 记

$$N(t) = \sup\{n : S_n \leq t\},$$

称 $\{N(t), t \geq 0\}$ 为 **更新过程**.

显然, 更新过程是一计数过程, 并有

$$\{N(t) \geq n\} = \{S_n \leq t\}, \quad (2.9.1)$$

$$\{N(t) = n\} = \{S_n \leq t < S_{n+1}\} = \{S_n \leq t\} - \{S_{n+1} \leq t\}. \quad (2.9.2)$$

记 $F_n(x)$ 为 S_n 的分布函数, 由 $S_n = \sum_{k=1}^n X_k$, 易知

$$\begin{aligned} F_1(x) &= F(x), \\ F_n(x) &= \int_0^x F_{n-1}(x-u) dF(u) \quad (n \geq 2). \end{aligned}$$

即 $F_n(x)$ 是 $F(x)$ 的 n 重卷积 (简记 $F_n = F_{n-1} * F$). 记 $m(t) = E\{N(t)\}$, 称 $m(t)$ 为 **更新函数**.

定理 2.9.2 $\forall t \geq 0$,

$$m(t) = \sum_{n=1}^{\infty} F_n(t). \quad (2.9.3)$$

证:

$$m(t) = \sum_{n=0}^{\infty} nP\{N(t) = n\} = \sum_{n=1}^{\infty} P\{N(t) \geq n\} = \sum_{n=1}^{\infty} P(S_n \leq t).$$

即

$$m(t) = \sum_{n=1}^{\infty} F_n(t). \quad \square$$

推论 若对 $\forall t \geq 0, F(t) < 1$, 则

$$m(t) \leq F(t)(1 - F(t))^{-1}. \quad (2.9.4)$$

证: 由归纳可得 $F_n(t) \leq (F(t))^n$, 再利用 (2.9.3) 即得. \square

定理 2.9.3 $\forall t \geq 0, m(t)$ 满足下列更新方程

$$m(t) = F(t) + \int_0^t m(t-u) dF(u). \quad (2.9.5)$$

证: 由 (2.9.3) 得

$$m(t) = F(t) + \sum_{n=2}^{\infty} F_n(t).$$

将下式

$$F_n(t) = \int_0^t F_{n-1}(t-u) dF(u)$$

代入即得 (2.9.5) 式. □

若令

$$\begin{aligned} \tilde{m}(s) &= \int_0^{\infty} e^{-st} dm(t), \\ \tilde{F}(s) &= \int_0^{\infty} e^{-st} dF(t). \end{aligned}$$

从 (2.9.5) 易得

$$\tilde{m}(s) = \frac{\tilde{F}(s)}{1 - \tilde{F}(s)}, \quad (2.9.6)$$

$$\tilde{F}(s) = \frac{\tilde{m}(s)}{1 + \tilde{m}(s)}. \quad (2.9.7)$$

由拉氏变换与逆变换是一一对应的, 可知 $F(t)$ 与 $m(t)$ 亦是一一对应的.

更新过程的最初物理原型是零件的连续更换, 一个零件在零时刻开始工作, 在 X_1 失效, 然后马上被第二个更换, 一般, 第 n 个零件在 $\sum_{i=1}^n X_i$ 时失效, 随之马上换一新零件. 通常假定各零件寿命是独立同分布的即 $P(X_n \leq x) = F(x)$, 显然这一更换过程中 $N(t)$ 表示在 $[0, t]$ 的更新数目. 现在, 更新过程在生物遗传, 排水系统, 可靠性工程, 人口增长, 经济管理等领域有着广泛应用.

§ 2.10 若干极限定理与基本更新定理

令 $\mu = EX_n$, 由 $F(0) < 1$ 易证 $\mu > 0$, 我们有:

命题 2.10.1

$$P\left(\lim_{n \rightarrow \infty} \frac{S_n}{n} = \mu\right) = 1 \quad (2.10.1)$$

或记为

$$\lim_{n \rightarrow \infty} \frac{S_n}{n} = \mu \quad (\text{d.s.}).$$

证: 由强大数定律即得. □

推论 1:

$$P(\lim_{n \rightarrow \infty} S_n = \infty) = 1 \quad (2.10.1a)$$

证: 由 $X_n \geq 0$ 有 $n \uparrow$ 时 $S_n \uparrow$, 故 $\lim_{n \rightarrow \infty} S_n$ 存在. 下证 $P(\lim_{n \rightarrow \infty} S_n = \infty) = 1$. 用反证法, 若不然, 存在 $M > 0$, 有 $P(\lim_{n \rightarrow \infty} S_n \leq M) = \alpha > 0$, 得 $P(\lim_{n \rightarrow \infty} \frac{S_n}{n} = 0) \geq \alpha > 0$, 从而 $P(\lim_{n \rightarrow \infty} \frac{S_n}{n} \neq \mu) \geq \alpha > 0$, 与 $P(\lim_{n \rightarrow \infty} \frac{S_n}{n} = \mu > 0) = 1$ 相矛盾, 因此 (2.10.1a) 式得证. \square

推论 2: $\forall t \geq 0$,

$$m(t) = \sum_{n=1}^{\infty} F_n(t) < \infty.$$

证: 当 $t = 0$ 时,

$$m(0) \leq \frac{F(0)}{1 - F(0)} < \infty.$$

下面考虑 $t > 0$, 由 $F^{(k)}(t)$ 的单调性, 易知 $F_{n+m}(t) \leq F_n(t)F_m(t)$, 从而有

$$F_{nr+m}(t) \leq (F_r(t))^n F_m(t), \quad 1 \leq m \leq r-1.$$

又由 $P(\lim_{n \rightarrow \infty} S_n = \infty) = 1$ 知, 对 $\forall t > 0$, 存在充分大的 $r \geq 1$, 使 $P(S_r > t) = \beta > 0$, 即 $F_r(t) = P(S_r \leq t) = 1 - \beta < 1$. 于是

$$m(t) = \sum_{k=1}^{\infty} F_k(t) = \sum_{n=0}^{\infty} \sum_{m=1}^r F_{nr+m}(t) \leq \sum_{n=0}^{\infty} r(F_r(t))^n F(t) = \frac{rF(t)}{1 - F_r(t)} < \infty.$$

记 $N(\infty) = \lim_{t \rightarrow \infty} N(t)$, 则有:

命题 2.10.2

$$P(N(\infty) = \infty) = 1. \quad (2.10.2)$$

证: 因

$$\{N(\infty) < \infty\} = \bigcup_{n=1}^{\infty} \{S_n = \infty\} = \bigcup_{n=1}^{\infty} \{X_n = \infty\},$$

故

$$0 \leq P(N(\infty) < \infty) = P\left(\bigcup_{n=1}^{\infty} (X_n = \infty)\right) \leq \sum_{n=1}^{\infty} P(X_n = \infty) = 0,$$

命题得证. \square

命题 2.10.3

$$P\left(\lim_{t \rightarrow \infty} \frac{N(t)}{t} = \frac{1}{\mu}\right) = 1. \quad (2.10.3)$$

证: 记

$$A = \{\omega : N(\infty) = \infty\},$$

$$B = \{\omega : \lim_{n \rightarrow \infty} \frac{S_n}{n} = \mu\},$$

$$C = \{\omega : \lim_{t \rightarrow \infty} \frac{S_{N(t)}}{N(t)} = \mu\}.$$

则由 $P(A) = P(B) = 1$ (命题 2.10.1 及 2.10.2) 易得 $P(AB) = 1$, 又 $AB \subset C$ 得 $P(C) = 1$. 再由

$$S_{N(t)} \leq t < S_{N(t)+1}$$

得

$$\frac{S_{N(t)}}{N(t)} \leq \frac{t}{N(t)} \leq \frac{S_{N(t)+1}}{N(t)+1} \cdot \frac{N(t)+1}{N(t)}.$$

令 $D = \{\omega : \lim_{t \rightarrow \infty} \frac{N(t)}{t} = \frac{1}{\mu}\}$, 则对 $\forall \omega \in C$, 有

$$\lim_{t \rightarrow \infty} \frac{S_{N(t)}}{N(t)} = \lim_{t \rightarrow \infty} \frac{t}{N(t)} = \lim_{t \rightarrow \infty} \frac{S_{N(t)+1}}{N(t)+1} \cdot \frac{N(t)+1}{N(t)} = \mu,$$

即 $C \subset D$, 得 $1 = P(C) \leq P(D) \leq 1$. 故 $P(D) = 1$, 命题得证. \square

为了讨论 Wald 等式, 先引出停时的概念.

定义 设 $\{X_n, n \geq 1\}$ 为随机序列, T 为取非负整数随机变量, 若对任一 $n \in \{0, 1, 2, \dots\}$, 事件 $\{T = n\}$ 仅依赖于 X_1, X_2, \dots, X_n , 而与 X_{n+1}, X_{n+2}, \dots 独立, 则称 T 关于 $\{X_n, n \geq 1\}$ 是 **停时** (Stopping time, 或称 Markov time).

直观意义是: 当我们依次观察诸 X_n , 以 N 表示在停止观察之前所观察的次数, 如果 $N = n$, 那么我们是在已经观察 X_1, X_2, \dots, X_n 后, 还未观察 X_{n+1}, X_{n+2}, \dots 前停止观察的.

定理 2.10.4 (Wald 等式) 设 $\{X_n, n \geq 1\}$ 独立同分布, $\mu = EX_n < \infty$, X_n 与 X 同分布, T 关于 $\{X_n, n \geq 1\}$ 是停时, 且 $ET < \infty$, 则

$$E\left(\sum_{n=1}^T X_n\right) = (EX)(ET). \quad (2.10.4)$$

证: 令

$$I_n = \begin{cases} 1, & T \geq n, \\ 0, & T < n. \end{cases}$$

则

$$\sum_{n=1}^T X_n = \sum_{n=1}^{\infty} X_n I_n.$$

由于 $\{I_n = 0\} = \{T < n\} = \bigcup_{k=1}^{n-1} \{T = k\}$ 仅依赖于 X_1, X_2, \dots, X_{n-1} 而与 X_n, X_{n+1}, \dots 独立, 且 $\{I_n = 1\} = \{\bigcup_{k=1}^{n-1} \{T = k\}\}^c$ 也与 X_n, X_{n+1}, \dots 独立, 因此 I_n 与 X_n 独立, 于是

$$E\{I_n X_n\} = (EX_n)\{EI_n\},$$

故

$$\begin{aligned} E\left(\sum_{n=1}^T X_n\right) &= E\left\{\sum_{n=1}^{\infty} X_n I_n\right\} = \sum_{n=1}^{\infty} (EX_n)(EI_n) \\ &= EX \cdot \sum_{n=1}^{\infty} (EI_n) = EX \sum_{n=1}^{\infty} P(T \geq n) = (EX) \cdot (ET). \quad \square \end{aligned}$$

例 2.10.5 $\{X_n, n \geq 1\}$ 独立同分布, 且 $P(X_n = 1) = P(X_n = 0) = \frac{1}{2}$, 记

$$T = \min\{n : \sum_{i=1}^n X_i = 10\},$$

可验证 T 关于 $\{X_n, n \geq 1\}$ 是停时, 若 $X_n = 1$ 表示第 n 次试验成功, 则 T 可看作是取得 10 次成功的试验停止时间, 由 (2.10.4) 得 $E\{\sum_{n=1}^T X_n\} = \frac{1}{2}ET$. 但由 T 的定义知 $X_1 + X_2 + \cdots + X_n = 10$, 故 $ET = 20$. \square

例 2.10.6 $\{X_n, n \geq 1\}$ iid, 且 $P(X_n = 1) = p, P(X_n = -1) = 1 - p = q \geq 0$, 记

$$T = \min\{n : \sum_{i=1}^n X_i = 1\}.$$

易验证 T 关于 $\{X_n, n \geq 1\}$ 是停时. 它可看作是一个赌徒的停时, 他在每局赌博中赢一元或输掉一元的概率分别为 p 与 q ($p + q = 1$), 且决定一旦赢一元就罢手.

当 $p > q$ 时, 由第三章可以证明 $ET < \infty$. 此时应用 Wald 等式得

$$(p - q)ET = E(X_1 + \cdots + X_T) = 1,$$

从而 $ET = (p - q)^{-1}$.

当 $p = q = \frac{1}{2}$ 时, 若应用 Wald 等式, 有 $E(X_1 + \cdots + X_T) = (EX)(ET)$, 然而, $EX = 0, X_1 + \cdots + X_T \equiv 1$. 从而得出矛盾, 所以当 $p = q = \frac{1}{2}$ 时, Wald 等式不再成立. 这就得出结论: $ET = \infty$. \square

我们现在转到更新过程 $\{X_n, n \geq 1\}$ 及 $N(t) = \sup\{n : \sum_{i=1}^n X_i \leq t\}$. 可以证明: $N(t) + 1$ 关于 $\{X_n, n \geq 1\}$ 是停时. 事实上, $\{N(t) + 1 = n\} = \{N(t) = n - 1\} = \{S_{n-1} \leq t < S_n\}$ 仅依赖于 X_1, \cdots, X_n 且独立于 X_{n+1}, \cdots , 故由 Wald 等式可推得以下推论:

推论 当 $EX_n = \mu < \infty$ 时

$$E[S_{N(t)+1}] = \mu[m(t) + 1]. \quad \square \quad (2.10.5)$$

现在我们可以证明以下定理:

定理 2.10.8 (基本更新定理) (The Elementary Renewal Theory)

$$\lim_{t \rightarrow \infty} \frac{m(t)}{t} = \frac{1}{\mu} \quad (\text{其中 } \frac{1}{\infty} = 0). \quad (2.10.6)$$

证：先设 $\mu < \infty$, 由 $S_{N(t)+1} > t$, 知 $\mu[m(t) + 1] > t$, 得

$$\liminf_{t \rightarrow \infty} \frac{m(t)}{t} \geq \frac{1}{\mu}. \quad (2.10.6a)$$

另一方面, 任意给定一常数 M , 令

$$\bar{X}_n = \begin{cases} X_n, & X_n \leq M, \\ M, & X_n > M. \end{cases} \quad n \in \mathbb{N}_0 = \{0, 1, 2, \dots\},$$

$$\bar{S}_0 = 0,$$

$$\bar{S}_n = \sum_{i=1}^n \bar{X}_i,$$

$$\bar{N}(t) = \sup\{n : n \geq 0, \bar{S}_n \leq t\},$$

$$\bar{m}(t) = E\{\bar{N}(t)\}.$$

显然 $\mu_M = E\bar{X}_n \leq \mu$, $\bar{S}_n \leq S_n$, $\bar{N}(t) \geq N(t)$, $\bar{m}(t) \geq m(t)$, $\bar{S}_{N(t)+1} \leq t + M$. 得,

$$\mu_M(1 + m(t)) \leq t + M,$$

即

$$\frac{m(t)}{t} \leq \frac{1}{\mu_M} + \frac{1}{t} \left(\frac{M}{\mu_M} - 1 \right).$$

故

$$\limsup_{t \rightarrow \infty} \frac{m(t)}{t} \leq \frac{1}{\mu_M} \quad (\forall M > 0).$$

又

$$\mu_M = \int_0^M [1 - F(x)] dx.$$

令 $M \rightarrow \infty$, 有

$$\lim_{M \rightarrow \infty} \mu_M = \lim_{M \rightarrow \infty} \int_0^M (1 - F(x)) dx = \int_0^\infty (1 - F(x)) dx = \mu.$$

故当 $M \rightarrow \infty$ 时

$$\limsup_{t \rightarrow \infty} \frac{m(t)}{t} \leq \frac{1}{\mu}. \quad (2.10.6b)$$

综合 (2.10.6a) 及 (2.10.6b) 知 $\mu < \infty$ 时 (2.10.6) 成立. 如 $\mu = \infty$, 那么由 $\mu_M < \infty$, 对截尾过程应用上述结论有

$$\limsup_{t \rightarrow \infty} \frac{m(t)}{t} \leq \limsup_{t \rightarrow \infty} \frac{\bar{m}(t)}{t} = \frac{1}{\mu_M} \geq 0 \quad (\forall M > 0),$$

令 $M \rightarrow \infty$, 得

$$\limsup_{t \rightarrow \infty} \frac{m(t)}{t} \leq \lim_{M \rightarrow \infty} \frac{1}{\mu_M} = 0.$$

从而结论成立. □

§ 2.11 更新方程与关键更新定理

在定理 2.9.3 中, 已证明了更新函数 $m(t)$ 满足 (2.9.5) 更新方程, 本节讨论更为一般的更新方程及其解.

设已知函数 $a(t)$ 及分布函数 $F(t)$, 若未知函数 $A(t)$ 满足积分方程

$$A(t) = a(t) + \int_0^t A(t-x) dF(x). \quad (2.11.1)$$

则称 (2.11.1) 为 **更新方程**.

更新方程在什么条件下, 解存在且唯一? 有何性质?

定理 2.11.1 设 $a(t)$ 为一有界函数, $F(t)$ 为分布函数, 则满足更新方程 (2.11.1) 的解存在且唯一, 其解在有限区间上有界, 且其解 $A(t)$ 可表为

$$A(t) = a(t) + \int_0^t a(t-x) dm(x), \quad (2.11.2)$$

其中 $m(t) = \sum_{n=1}^{\infty} F_n(t)$, $F_1(t) = F(t)$, $F_n(t) = \int_0^t F_{n-1}(t-x) dF(x)$.

证: 先证 $A(t)$ 在任一有限区间上有界. 对 $\forall s > 0$, 由 $a(t)$ 有界, 及命题 2.10.1 的推论 2 知 $m(t)$ 有界. 故若 $A(t)$ 用 (2.11.2) 表示, 则

$$\sup_{0 \leq t \leq s} |A(t)| \leq \sup_{0 \leq t \leq s} |a(t)| + \int_0^s \sup_{0 \leq t \leq s} |a(t)| dm(x) \leq \sup_{0 \leq t \leq s} |a(t)| (1 + m(s)) < \infty.$$

其次证明由 (2.11.2) 表示的 $A(t)$ 满足方程 (2.11.1),

$$\begin{aligned} A(t) &= a(t) + m * a(t) = a(t) + \left(\sum_{n=1}^{\infty} F_n \right) * a(t) = a(t) + F * a(t) + \left(\sum_{n=2}^{\infty} F_n \right) * a(t) \\ &= a(t) + F * [a(t) + \sum_{n=1}^{\infty} F_n * a(t)] = a(t) + F * A(t). \end{aligned}$$

最后证解的唯一性, 即证明任何满足 (2.11.1) 式且在有限区间上有界的解 $A(t)$ 总可以用 (2.11.2) 表示. 注意到用 (2.11.1) 式 $A(t)$ 的表达式重复代入 (2.11.1) 式右边作为 $A(t)$ 的逐步逼近, 即用 $A = a + F * A$ 代入它的右边, 得

$$\begin{aligned} A &= a + F * (a + F * A) = a + F * a + F * (F * A) && (\text{记 } F_2 = F * F) \\ &= a + F * a + F_2 * A = a + F * a + F_2 * (a + F * A) && (\text{记 } F_3 = F_2 * F) \\ &= a + F * a + F_2 * a + F_3 * A = \cdots && (\text{记 } F_n = F_{n-1} * F) \\ &= a + \sum_{K=1}^{n-1} (F_K * a + F_n * A). \end{aligned}$$

由命题 2.10.1 的推论 2 知, $\forall t > 0, \lim_{n \rightarrow \infty} F_n(t) = 0$. 故

$$|F_n * A(t)| \leq \sup_{0 \leq x \leq t} \{|A(t-x)|F_n(t)\} \rightarrow 0 \quad (A(t) \text{ 有界, 对 } \forall t \geq 0).$$

类似地由 $a(t)$ 有界, $m(t) = \sum_{n=1}^{\infty} F_n(t) < \infty$, 得

$$\lim_{n \rightarrow \infty} \left(\sum_{k=1}^{n-1} F_k \right) * a(t) = \left(\sum_{k=1}^{\infty} F_k \right) * a(t) = m * a(t),$$

于是

$$A(t) = \lim_{n \rightarrow \infty} [a(t) + \left(\sum_{k=1}^{n-1} F_k \right) * a(t) + F_n * A(t)] = a(t) + m * a(t).$$

因而 (2.11.1) 的一般解 $A(t)$ 就是 (2.11.2) 式, 唯一性得证. \square

为叙述关键更新定理, 引入若干名词概念, 非负 r.v. X 称为 **格点的**(Lattice), 若存在 $d \geq 0$, 满足 $\sum_{n=0}^{\infty} P(X = nd) = 1$. 即 X 是格点的, 意指 X 只取某个非负数 d 的整数倍. 具有这种性质的最大的 d , 称为 X 的周期. 若 F 是 X 的分布函数且 X 是格点的, 则称 F 是格点的.

定理 2.11.2 (Blackwill 定理): 设 $F(x)$ 为非负 r.v. 的分布函数, $F_n = F_{n-1} * F, F_1 = F, m(t) = \sum_{n=1}^{\infty} F_n(t)$.

(1) 如 F 是非格点的, 则对 $\forall a \geq 0$,

$$\lim_{t \rightarrow \infty} [m(t+a) - m(t)] = \frac{a}{\mu}. \quad (2.11.3)$$

(2) 如 F 是格点, 周期为 d , 则

$$\lim_{n \rightarrow \infty} [m((n+1)d) - m(nd)] = \frac{d}{\mu}. \quad (2.11.4)$$

证: (略; 可参见 I.W.Feller, "An Introduction to Probability Theory and Its Applications" Vol.II Wiley New York 1966). \square

本定理说明: 如 F 非格点, 随着时间远离原点, 原先的影响逐渐消失, 那么在远离原点, 长为 a 的区间内更新的期望次数趋于 $\frac{a}{\mu}$. 这与直觉相吻合. 如 F 是周期为 d 的格点的, 此时更新只发生在形如 nd 的时刻上, 因而 (2.11.4) 成立.

设 h 是定义在 $[0, \infty)$ 上的函数, 对任意 $\delta > 0$, 记 $\underline{m}_n(\delta), \overline{m}_n(\delta)$ 分别表 $h(t)$ 在区间 $(n-1)\delta \leq t \leq n\delta$ 上的下, 上确界, 若它满足: 对 $\forall \delta > 0, \sum_{n=1}^{\infty} \underline{m}_n(\delta), \sum_{n=1}^{\infty} \overline{m}_n(\delta)$ 有限, 且

$$\lim_{\delta \rightarrow 0} \delta \sum_{n=1}^{\infty} \overline{m}_n(\delta) = \lim_{\delta \rightarrow 0} \delta \sum_{n=1}^{\infty} \underline{m}_n(\delta),$$

就称 $h(t)$ 是直接 Riemann 可积的.

易证每一个单调且绝对可积函数 $g(t)$ (即 $\int_0^{\infty} |g(t)| dt < \infty$) 必是直接 R-可积的.

定理 2.11.3 (关键更新定理) 设 F 是均值为 μ 的非负随机变量的分布函数, $F(0) < 1$. $a(t)$ 是直接 \mathbb{R}^- 可积, $A(t)$ 是更新方程

$$A(t) = a(t) + \int_0^t A(t-x) dF(x)$$

的解.

(1) 若 F 非格点的, 则

$$\lim_{t \rightarrow \infty} A(t) = \begin{cases} \frac{1}{\mu} \int_0^\infty a(t) dt, & \mu < \infty, \\ 0, & \mu = \infty. \end{cases} \quad (2.11.5)$$

(2) 若 F 是周期为 d 的格点的, $\forall c > 0$, 有

$$\lim_{n \rightarrow \infty} A(c + nd) = \begin{cases} \frac{d}{\mu} \sum_{n=0}^\infty a(c + nd), & \mu < \infty, \\ 0, & \mu = \infty. \end{cases} \quad (2.11.6)$$

证明从略, 可参见 I.W.Feller 书 Vol.II.

关键更新定理是一个非常重要, 十分有用的结果. 如在计算 t 时刻的概率, 期望的极限性态时, 常要用到它, 举例说明如下:

(1) 剩余寿命的极限分布

记 $r_t = S_{N(t)+1} - t$, 表 t 时刻的剩余寿命, 对任意固定 $z > 0$, 令 $A_z(t) = P(r_t > z)$. 为求 $\lim_{t \rightarrow \infty} A_z(t)$, 先证 $A_z(t)$ 满足更新方程

$$A_z(t) = 1 - F(t+z) + \int_0^t A_z(t-x) dF(x). \quad (2.11.7)$$

易知

$$P(r_t > z | X_1 = x) = \begin{cases} 1, & x > t+z, \\ 0, & t+z \geq x > t, \\ A_z(t-x), & t \geq x > 0. \end{cases}$$

由全概公式

$$\begin{aligned} A_z(t) &= \int_0^\infty P(r_t > z | X_1 = x) dF(x) \\ &= \int_0^t A_z(t-x) dF(x) + \int_t^{t+z} 0 \cdot dF(x) + \int_{t+z}^\infty dF(x) \\ &= \int_0^t A_z(t-x) dF(x) + [1 - F(t+z)]. \end{aligned}$$

因此 (2.11.7) 得证. 设

$$\begin{aligned} \mu = EX_1 &= \int_0^\infty [1 - F(x)] dx < \infty, \\ a(t) &= 1 - F(t+z). \end{aligned}$$

由

$$\int_0^\infty [1 - F(t+z)] dt = \int_z^\infty [1 - F(y)] dy < \mu < \infty.$$

且 $a(t) = 1 - F(t+z)$ 单调, 故 $a(t)$ 直接 R^- 可积, 应用 (2.11.5) 式, 得

$$\lim_{t \rightarrow \infty} P(r_t > z) = \lim_{t \rightarrow \infty} A_z(t) = \mu^{-1} \int_x^\infty [1 - F(y)] dy \quad (\forall z > 0).$$

这就是 r_t 的极限分布.

(2) 交错更新过程的极限分布

考虑只有二个状态的系统: 开 (用 “1” 表示) 或关 (用 “0” 表示). 系统在 $t=0$ 时是开的且持续开的时间为 Z_1 ; 接着关闭且持续时间为 Y_1 ; 之后又开着持续时间为 Z_2 , 又关闭时间为 Y_2 , 如此开并交替重复下去. 设 $\{(Z_n, Y_n), n \geq 1\}$ 为独立同分布随机向量序列 (则 $\{Z_n, n \geq 1\}$ iid, $\{Y_n, n \geq 1\}$ iid, 但允许 Z_n 与 Y_n 相依). 记 $X_n = Z_n + Y_n, S_0 = 0, S_n = \sum_{i=1}^n X_i, N(t) = \sup\{n : n \geq 0, S_n \leq t\}$. 则 $\{N(t), t \geq 0\}$ 为更新过程, 记

$$\zeta_t = \begin{cases} 1, & S_n \leq t < S_n + Z_{n+1}, \\ 0, & S_n + Z_{n+1} \leq t < S_{n+1}. \end{cases} \quad n \in \mathbb{N}.$$

称 $\{\zeta_t, t \geq 0\}$ 为 **交错更新过程**.

设 $H(t) = P(Z_n \leq t), G(t) = P(Y_n \leq t), F(t) = P(X_n \leq t)$, 并记 $P(t) = P(\zeta_t = 1), Q(t) = P(\zeta_t = 0)$, 则有:

定理 2.11.4 若 $EX_n < \infty$, 且 F 为非格点的, 则

$$\begin{aligned} \lim_{t \rightarrow \infty} P(t) &= \frac{EZ_1}{EZ_1 + EY_1}, \\ \lim_{t \rightarrow \infty} Q(t) &= \frac{EY_1}{EZ_1 + EY_1}. \end{aligned}$$

证: 注意

$$\{\zeta_t = 1\} = \{S_{N(t)} \leq t < S_{N(t)} + Z_{N(t)+1}\} = \bigcup_{n=0}^{\infty} \{S_n \leq t < S_n + Z_{n+1}\}.$$

由全概公式

$$\begin{aligned}
 P(t) &= P\{S_{N(t)} \leq t < S_{N(t)} + Z_{N(t)+1}\} = \sum_{n=0}^{\infty} P(S_n \leq t < S_n + Z_{n+1}) \\
 &= P(Z_1 > t) + \sum_{n=1}^{\infty} \int_0^t P\left[\sum_{i=2}^n X_i \leq t-x < \sum_{i=2}^n X_i + Z_{n+1}\right] dF(x) \\
 &= 1 - H(t) + \int_0^t \sum_{n=1}^{\infty} P[S'_{n-1} \leq t-x < S'_{n-1} + Z'_n] dF(x) \\
 &\quad (\text{其中 } S'_0 = 0, S'_{n-1} = \sum_{i=2}^n X_i \ (n \geq 2), Z'_n = Z_{n+1}) \\
 &= 1 - H(t) + \int_0^t P(t-x) dF(x).
 \end{aligned}$$

即 $P(t)$ 满足更新方程 (2.11.1), 此时 $a(t) = 1 - H(t)$, 由 $EX_n < \infty, Z_n \geq 0, Y_n \geq 0$, 故

$$EZ_1 = \int_0^{\infty} (1 - H(t)) dt \leq EX_1 < \infty.$$

又 $1 - H(t)$ 单调, 得 $1 - H(t)$ 直接 R^- 可积, 这样应用定理 2.11.3 得

$$\lim_{t \rightarrow \infty} P(t) = \frac{1}{EX_1} \int_0^{\infty} (1 - H(t)) dt = \frac{EZ_1}{EZ_1 + EY_1}.$$

类似可证 $\lim_{t \rightarrow \infty} Q(t)$ 的结果. □

(3) 更新报酬过程

有许多概率模型是下列更新报酬模型的特殊情形. 考虑更新过程 $\{N(t), t \geq 0\}$ 有着时间间隔 $X_n (n \geq 1)$, 其分布为 F , 设每当一个更新发生时我们得到一个报酬, 用 R_n 表第 n 次更新收到的报酬. 设 $\{R_n, n \geq 1\}$ iid, $R_n \leq 0$, a.s., 并设随机向量 $\{(X_n, R_n) n \geq 1\}$ iid, 然而允许 R_n 依赖于 X_n . 令 $R(t) = \sum_{n=1}^{N(t)} R_n$, $R(t)$ 表到 t 时为止的总报酬, 令 $ER_n = ER, EX = EX_n = \mu$, 则有:

定理 2.11.5 若 $ER < \infty, EX = \mu < \infty$, 那么

(1)

$$P\left(\lim_{t \rightarrow \infty} \frac{R(t)}{t} = \frac{ER}{EX}\right) = 1,$$

或记

$$\lim_{t \rightarrow \infty} \frac{R(t)}{t} = \frac{ER}{EX} \quad (\text{a.s.}).$$

(2)

$$\lim_{t \rightarrow \infty} \frac{E(R(t))}{t} = \frac{ER}{EX}.$$

证: 由于

$$\frac{R(t)}{t} = \frac{\sum_{n=1}^{N(t)} R_n}{t} = \frac{\sum_{n=1}^{N(t)} R_n}{N(t)} \cdot \frac{N(t)}{t}.$$

故由强大数定律及更新过程强大数定律, 有

$$\lim_{t \rightarrow \infty} \frac{\sum_{n=1}^{N(t)} R_n}{N(t)} = ER \quad (\text{a.s.}).$$

及

$$\lim_{t \rightarrow \infty} \frac{N(t)}{t} = \frac{1}{EX} \quad (\text{a.s.}).$$

知 (1) 成立.

为证 (2), 首先注意 $(N(t) + 1)$ 关于 $\{X_n, n \geq 1\}$ 是停时, 因而也是 $\{R_n, n \geq 1\}$ 的停时. 由 Wald 等式

$$E\left[\sum_{n=1}^{N(t)} R_n\right] = E\left[\sum_{n=1}^{N(t)+1} R_n\right] - E[R_{N(t)+1}] = [m(t) + 1]ER - E[R_{N(t)+1}].$$

故

$$\frac{ER(t)}{t} = \frac{m(t) + 1}{t}ER - \frac{E[R_{N(t)+1}]}{t}.$$

如果我们能证明: 当 $t \rightarrow \infty$ 时 $\frac{E[R_{N(t)+1}]}{t} \rightarrow 0$. 那么, 由基本更新定理即可证 (2) 成立. 为此, 令 $g(t) = E[R_{N(t)+1}]$, 用 “更新技巧”:

$$E(R_{N(t)+1} | X_1 = x) = \begin{cases} E(R_1 | X_1 = x), & x > t; \\ g(t - x), & x \leq t. \end{cases}$$

因为 $X_1 = x > t$ 时, $N(t) = 0$; 而 $x \leq t$ 时, 将时间原点移至 x , 过程从新开始. 所以

$$g(t) = \int_0^\infty E(R_{N(t)+1} | X_1 = x) dF(x) = h(t) + \int_0^t g(t - x) dF(x)$$

其中 $h(t) = \int_t^\infty E(R_1 | X_1 = x) dF(x)$. 事实上, 对一切 t ,

$$\begin{aligned} |h(t)| &\leq \int_t^\infty |E(R_1 | X_1 = x)| dF(x) \leq \int_t^\infty E(|R_1| | X_1 = x) dF(x) \\ &\leq \int_0^\infty E(R_1 | X_1 = x) dF(x) = E|R_1| < \infty. \end{aligned}$$

得 $t \rightarrow \infty, h(t) \rightarrow 0$, 且对所有 $t \geq 0, h(t) \leq E|R_1|$. 因此, $\forall \varepsilon > 0$ 存在 T , 当 $t > T$ 时 $|h(t)| < \varepsilon$. 由定理 (2.11.1) 有

$$g(t) = h(t) + \int_0^t h(t - x) dm(x).$$

利用基本更新定理.

$$\begin{aligned} \frac{g(t)}{t} &\leq \frac{|h(t)|}{t} + \int_0^{t-T} \frac{|h(t - x)|}{t} dm(x) + \int_{t-T}^t \frac{|h(t - x)|}{t} dm(x) \\ &\leq \frac{\varepsilon}{t} + \frac{\varepsilon m(t - T)}{t} + ER_1 \frac{m(t) - m(t - T)}{t} \quad (t > T) \\ &\rightarrow \frac{\varepsilon}{EX} \quad (t \rightarrow \infty). \end{aligned}$$

练习题

由 ε 的任意性, 得 $\lim_{t \rightarrow \infty} \frac{g(t)}{t} = 0$. 于是 (2) 成立. \square

注: 定理说明, 对于长时间运行后求得的期望平均报酬就等于一个周期内得到的期望报酬除以一个周期的期望时间.

(4) 计数模型

这里指的计数器是一种用于检测与记录瞬时脉冲信号的装置. 例如, 常见的 Geiger-Muller 计数器及电子放大器等. 所有具体的物理计数器都有缺点: 它不能检测到所有进入检测区域的信号. 在记录一个粒子或一个信号后, 计数器必须恢复或更新自己后才能接收下一个信号, 在调整期 (或称为锁住期, 不接收期) 内到达信号会丢失, 我们必须区分到达粒子 (信号) 和记录粒子 (信号). 实验者通过该计数器只能观察到记录粒子信号, 希望由此发现到达过程的性质. 假定信号按时间间隔 $\{X_n, n \geq 1\}$ 的更新过程到达.

$F(x) = P(X_n \leq x)$. 计数模型按其锁住期加以区分. 这里只讨论一类常见的 I 型计数器, 设 $t = 0$ 时一个信号到达计数器, 在 Y_1 锁住期内不接收到达的信号, 记录的第一个信号是 Y_1 后到达的信号, 由于这个信号的记录, 计数器又有一个锁住期 Y_2 , 下一个记录的信号是计数器恢复工作后第一个到达的信号, 如此重复进行, 其中锁住期依次记为 Y_1, Y_2, \dots , 设其独立同分布 $G(y) = P(Y_n \leq y)$ 且 $\{Y_n, n \geq 1\}$ 与 $\{X_n, n \geq 1\}$ 独立. 设 Z_1 表示第一个信号记录的时间间隔 (不包括原点), 因为这过程在每次记录之后开始恢复, $Z_n (n = 2, 3, \dots)$ 为 $(n-1)$ 次和 n 次记录的时间间隔, 因为这过程在每次记录之后开始恢复, 知 $\{Z_n, n \geq 1\}$ 构成一更新过程, 如图 2.11.9 所示. 设 $S_0 = 0, S_n = \sum_{i=1}^n X_i, N(t) = \sup\{n : n \geq 0, S_n \leq t\}, \gamma_t = S_{N(t)+1} - t, A_x(t) = P(\gamma_t > x)$. 由 $\{X_n, n \geq 1\}$ 与 $\{Y_n, n \geq 1\}$ 独立及注意到 $Z_1 = Y_1 + \gamma_{y_1} = S_{N(y_1)+1}$, 故 Z_1 的分布为

$$P(Z_1 \leq z) = \int_0^z P(y + \gamma_y \leq z | Y_1 = y) dG(y) = \int_0^z \{1 - A_{z-y}(y)\} dG(y).$$

$A_z(t)$ 由 (2.11.7) 求得, 这样 I 型计数器计数信号间的时间间隔分布就完全确定了. 进一步应用更新定理, 不难求得长期检测时, 每单位时间平均记录信号数是 $1/EZ_1$. 以及应用关键更新定理证明, 当 $t \rightarrow \infty$ 时, 记录的信号与到达信号数的比例是 EX_1/EZ_1 .

当到达信号是参数为 λ 的 Poisson 流时, 即 $F(x) = 1 - e^{-\lambda x}, x \geq 0$. 此时 γ_t 服从参数为 λ 的指数分布, Z_1 的分布变为

$$P(Z_1 \leq z) = \int_0^z G(z-y) \lambda e^{-\lambda y} dy.$$

练习题

61

2.1 下列事件有什么关系? 试指出并说明理由:

1. $(N(t) < n)$ 与 $(S_n > t)$;




图 2.11.9

2. $(N(t) \leq n)$ 与 $(S_n \geq t)$;
3. $(N(t) > n)$ 与 $(S_n < t)$;
4. $(W(t) > x)$ 与 $(N(t+x) - N(t) = 0)$.

2.2 $\{N(t), t \geq 0\}$ 为 Poisson 过程, 任给 $0 \leq s < t$, 证:

$$P(N(s) = k | N(t) = n) = C_n^k \left(\frac{s}{t}\right)^k \left(1 - \frac{s}{t}\right)^{n-k} \quad (0 \leq k \leq n).$$

2.3 设 $\{N(t), t \geq 0\}$ 为 Poisson 过程, 参数为 λ , 求或证明:

1. $E\{N(t)N(s+t)\}$;
2. $E(N(s+t)|N(s))$ 的分布律;
3. 任给 $0 \leq s \leq t$, 有 $P\{N(s) \leq N(t)\} = 1$;
4. 任给 $0 \leq s \leq t, \varepsilon > 0$, 有 $\lim_{t \rightarrow s} P\{N(t) - N(s) > \varepsilon\} = 0$.

2.4 设 U_k 是独立同 $(0, 1)$ 上均匀分布, $X_k = -\lambda^{-1} \ln U_k$ ($\lambda > 0$, 常数), 求:

1. X_k 的分布;
2. $S_n = X_1 + X_2 + \cdots + X_n$ 的分布;
3. $Z_n = 2\lambda S_n$ 的概率密度函数, 并与 $\chi^2(2n)$ 的密度函数比较.

2.5 求: $E(S_k | N(t) = n) \quad (k \leq n)$.

2.6 求 $W(t)$ 与 $V(t)$ 的分布及它们的联合分布.

2.7 证明定理 2.6.2.

2.8 证明定理 2.6.1.

2.9 求在 $N(t) = n$ 的条件下, S_k ($k < n$) 的条件概率密度.

2.10 设在某公路上, 汽车运输流动构成一 Poisson 流, 其强度等于每分钟 30 辆 (强度即参数 λ), 试求 n 辆汽车通过观察站的时间需要多于 x 秒的概率. (答案为:

$$\frac{1}{2^n (n-1)!} \int_x^\infty u^{n-1} e^{-\frac{u}{2}} du.)$$

练习题

2.11 设复合 Poisson 过程 $\{X(t), t \geq 0\}$, 求 $EX(t)$ 及 $D(X(t))$.

2.12 设 $\{N(t), t \geq 0\}$ 为条件 Poisson 过程

1. $N(t) = n$ 给定条件下, 求 t 时刻后首次事件发生的时间的条件分布;

2. 计算: $\lim_{h \rightarrow 0} \frac{P(N(h) \geq 1)}{h}$;

3. 求: $\lim_{h \rightarrow 0} \frac{P\{N(t+h) - N(t) = 1 | N(t) = n\}}{h}$.

2.13 考虑一个单服务员银行, 顾客到达按照速率为 λ 的 Poisson 过程, 服务员为每一位顾客的服务时间是 r.v. 分布函数为 G , 来客到达门口只是在当时服务员空闲时才准进来. 求:

1. 顾客进银行的速率是多少?

2. 顾客进银行占多大比例?

3. 服务员工作的时间占多大比例?

2.14 考虑一更新过程, 如果 $P(X_n = 1) = \frac{1}{3}, P(X_n = 2) = \frac{2}{3}$, 计算 $P(N(1) = k), P(N(2) = k), P(N(3) = k)$.

2.15 汽车到达大门, 每辆汽车随机长度 X , 其分布为 F , 第一辆汽车到达, 靠着大门停放. 每一辆后来的汽车停在前一辆车后面. 其间距离 Y 是一个 $[0, 1]$ 上均匀分布的 r.v., N_x 表示在离大门距离 x 内停在一条线的车数, 求: $\lim_{x \rightarrow \infty} \frac{EN_x}{x}$ (其中 $F(y) = 1 - e^{-y}, y \geq 0$).

2.16 设 $\{X_n, n \geq 1\}$ iid, X_n 的概率密度函数为

$$f(x) = \begin{cases} \rho e^{-\rho(x-\delta)}, & x > \delta, \\ 0, & x \leq \delta. \end{cases}$$

其中 $\delta > 0$ 给定. 求更新过程中的概率 $P(N(t) \geq k)$.

2.17 设 X_n 的概率密度 $f(x) = \lambda^2 x e^{-\lambda x}, x \geq 0$, 求相应的更新函数 $m(t)$.

2.18 求 Poisson 过程中, 全寿命 $\beta_t = S_{N(t)+1} - S_{N(t)}$ 的分布.

2.19 设 $\delta_t = t - S_{N(t)}$ 为更新过程的年龄, 证 $\{\delta_t, t \geq 0\}$ 是一个 Markov 过程, 并求其转移分布函数 $F(y; t, x) = P(\delta_{s+t} \leq y | \delta_s = x)$, 求 $\lim_{t \rightarrow \infty} P(\delta_t > z)$.

2.20 设 $A(t)$ 是更新方程 $A(t) = a(t) + \int_0^t A(t-x) dF(x)$ 的解, 其中 $a(t)$ 是一个有界非减函数, $a(0) = 0$, 求证 $\lim_{t \rightarrow \infty} \frac{A(t)}{t} = \frac{a^*}{\mu}$, 其中 $a^* = \lim_{t \rightarrow \infty} a(t), \mu < \infty$ 是相应于 F 的均值.

2.21 考虑一个分布函数为 F 的更新过程, 假设每一事件以概率 $1-q$ 被抹掉. 以比例因子 $\frac{1}{q}$ 扩大时间尺度, 证明事件流构成一更新过程, 其中事件之间的时间间隔分布函数是

$$F(x; q) = \sum_{n=1}^{\infty} (1-q)^{n-1} q F_n(x/q),$$

其中 F_n 为 F 的 n 重卷积.

2.22 (续问题 2.21) 设 $\phi(s)$ 为 $F(x)$ 的 Laplace 变换, 求 $F(x; q)$ 的 Laplace 变换 ($\phi(s, q) = \frac{q\phi(sq)}{1-(1-q)\phi(sq)}$).

2.23 设 n 个零件的寿命 X_1, X_2, \dots, X_n 是独立同指数分布, 参数为 λ . 该 n 个零件从 $t = 0$ 开始工作, 记 $X_{(1)} \leq X_{(2)} \leq \dots \leq X_{(r)} \leq \dots \leq X_{(n)}$ 为相继失效的时刻, 试求 $X_{(1)}, X_{(2)}, \dots, X_{(r)}$ 的联合概率密度函数 ($1 \leq r \leq n$).

2.24 同上, 令 $Y_1 = X_{(1)}, Y_i = X_{(i)} - X_{(i-1)}, 2 \leq i \leq n$. 试问 Y_1, Y_2, \dots, Y_n 是否独立? 同分布? 并证明你的猜想?

2.25 设 $\{N(t), t \geq 0\}$ 为时齐 Poisson 过程, $S_1, S_2, \dots, S_n, \dots$ 为事件相继发生的时刻.

1. 给定 $N(t) = n$, 试问 $S_1, S_2 - S_1, \dots, S_n - S_{n-1}$ 是否条件独立? 是否同分布? 试证明你的猜想?
2. 求 $E[S_1 | N(t)]$ 的分布律;
3. 利用 1. 及 2. 求 $E[S_k | N(t)]$ 的分布律;
4. 求在 $N(t) = n$ 下 S_i 与 $S_k (1 \leq i < k \leq n)$ 的条件联合概率密度.

2.26 设 $\{N(t), t \geq 0\}$ 是参数为 λ 的时齐 Poisson 过程, $S_0 = 0$, S_n 为第 n 个事件发生的时刻. 求:

1. (S_2, S_5) 的联合 p.d.f.;
2. $E(S_1 | N(t) \geq 1)$;
3. (S_1, S_2) 在 $N(t) = 1$ 下的条件 p.d.f..

2.27 设 $\{N_i(t), t \geq 0\}$ 是参数分别为 λ_i 的时齐 Poisson 过程, 且相互独立 ($i = 1, 2$). $S_0^{(i)} = 0$, $S_n^{(i)}$ 为第 i 个过程第 n 个事件发生的时刻.

1. 令 $N(t) = N_1(t) + N_2(t)$, 证明 $\{N(t), t \geq 0\}$ 是参数为 $\lambda_1 + \lambda_2$ 的时齐 Poisson 过程;
2. 求 $N_1(S_1^{(2)})$ 及 $N_1(S_2^{(2)})$ 的分布律;
3. 求 $S_{N_2(t)}^{(1)}$ 的 p.d.f..

2.28 (见 § 2.7) 若 $\rho_n \sim G(p)$, 即 $P(\rho_n = k) = (1-p)^{k-1}p, k \in \mathbb{N}$, 求平稳无后效流 $X(t)$ 的母函数与 $EX(t)$.

第三章 马尔可夫链

§ 3.1 定义与例子

本章讨论离散参数 $T = \{0, 1, 2, \dots\} = N_0$, 状态空间 $S = \{1, 2, \dots\}$ 可列的马尔可夫过程, 通常称为马尔可夫链 (Markov Chains), 简称马氏链 (M.C.).

马氏链最初由 Markov 于 1906 年研究而得名. 至今它的理论已发展得较为系统和深入. 它在自然科学, 工程技术及经济管理各领域中都有广泛的应用.

定义 随机序列 $\{X_n, n \geq 0\}$ 称为 **马尔可夫链**. 如果对任意 $i_0, i_1, \dots, i_n, i_{n+1} \in S, n \in N_0$ 及 $P\{X_0 = i_0, X_1 = i_1, \dots, X_n = i_n\} > 0$, 有:

$$P\{X_{n+1} = i_{n+1} | X_0 = i_0, X_1 = i_1, \dots, X_n = i_n\} = P\{X_{n+1} = i_{n+1} | X_n = i_n\}. \quad \square$$

(3.1.1)

(3.1.1) 式刻画了马氏链的特性, 称为马尔可夫性 (或无后效性), 简称马氏性.

定义 $\forall i, j \in S$, 称 $P\{X_{n+1} = j | X_n = i\} \triangleq p_{ij}(n)$ 为 n 时刻的一步转移概率. 若对 $\forall i, j \in S, p_{ij}(n) \equiv p_{ij}$, 与 n 无关, 则称 $\{X_n, n \geq 0\}$ 为齐次马氏链. 记 $P = (p_{ij})$, 称 P 为 $\{X_n, n \geq 0\}$ 的一步转移概率矩阵, 简称为转移矩阵 (Transition matrix). \square

本章仅限于讨论齐次马氏链.

为直观理解马氏性的意义, 设想一质点在一直线上的整数点上作随机运动. 以 X_n 表示该质点在时刻 n 的位置. $(X_n = i)$ 表示质点在时刻 n 处在 i 状态 (位置) 这一随机事件. 如果把时刻 n 看作“现在”, 时刻 $0, 1, \dots, n-1$ 表示“过去”, 时刻 $n+1$ 表示“将来”, 那么 (3.1.1) 式表明在已知过去 $X_0 = i_1, \dots, X_{n-1} = i_{n-1}$ 及现在 $X_n = i_n$ 的条件下, 质点在将来时刻 $n+1$ 处于状态 i_{n+1} (移动到 i_{n+1} 位置) 的条件概率, 只依赖于现在发生的事件 $(X_n = i_n)$, 而与过去历史曾发生过什么事件无关. 简言之, 在已知“现在”的条件下, “将来”与“过去”是独立的. $p_{ij}(n)$ 表示质点在时刻 n 由状态 i 出发, 于时刻 $n+1$ 转移到状态 j 的条件概率. 而齐次性: $p_{ij}(n) = p_{ij}$ 表示此转移概率与时刻 n 无关.

下面介绍若干例子.

(1). 独立随机变量和的序列

设 $\{\rho_n, n \geq 0\}$ 为独立同分布随机变量序列. 且 ρ_n 取值为非负整数, $P\{\rho_n = i\} = a_i, a_i \geq 0$, 且 $\sum_{i=0}^{\infty} a_i = 1$. 令 $X_0 = 0, X_n = \sum_{k=1}^n \rho_k$, 则易证 $\{X_n, n \geq 0\}$ 是一马氏链, 且

$$p_{ij} = \begin{cases} a_{j-i}, & j \geq i, \\ 0, & j < i. \end{cases}$$

显然 $\{\rho_n, n \geq 0\}$ 本身也是一马氏链.

(2). 直线上的随机游动

(a) 无限制的随机游动

设有一质点在数轴上随机游动, 每隔一单位时间 Δt (设 $\Delta t = 1$) 移动一次, 每次只能向左或向右移动 Δx 单位 (设 $\Delta x = 1$), 或原地不动. 设质点在 0 时刻的位置为 a , 它向右移动的概率为 $p \geq 0$, 向左移动的概率为 $q \geq 0$, 原地不动的概率为 $r \geq 0$, ($p + q + r = 1$), 且各次移动相互独立, 以 X_n 表示质点经 n 次移动后所处的位置. 则 $\{X_n, n \geq 0\}$ 是一马氏链, 且 $p_{i,i+1} = p, p_{i,i-1} = q, p_{ii} = r$, 其余 $p_{ij} = 0$.

(b) 带吸收壁的随机游动

设 (a) 中的随机游动限制在 $S = \{0, 1, 2, \dots, b\}$ 内, 当质点移动到状态 0 或 b 后就永远停留在该位置, 即 $p_{00} = 1, p_{bb} = 1$, 其余 $p_{ij} (1 \leq i, j \leq b-1)$ 同 (a). 这时序列 $\{X_n, n \geq 0\}$ 称为带两个吸收壁 0 和 b 的随机游动, 是一有限状态马氏链.

(c) 带反射壁的随机游动

如 (b) 中的质点到达 0 或 b 后, 下一次移动必返回到 1 或 $b-1$, 即 $p_{01} = 1, p_{b,b-1} = 1, p_{0j} = 0 (j \neq 1), p_{bj} = 0 (j \neq b-1)$, 其余同 (a). 称此 $\{X_n, n \geq 0\}$ 为带反射壁 0 和 b 的随机游动. 则 $\{X_n, n \geq 0\}$ 是一马氏链.

(d) 艾伦费斯特 (Ehrenfest) 模型

这是一个著名的粒子通过薄膜进行扩散过程的数学模型. 即一质点在状态空间 $S = \{-a, -a+1, \dots, -1, 0, 1, 2, \dots, a\}$ 中作随机游动, 且带有两个反射壁 a 和 $-a$, 其一步转移概率是:

$$\begin{cases} p_{i,i-1} = \frac{1}{2} \left(1 + \frac{i}{a}\right), & p_{i,i+1} = \frac{1}{2} \left(1 - \frac{i}{a}\right), & -a+1 \leq i \leq a-1, \\ p_{a,a-1} = 1, & p_{-a,-a+1} = 1, \\ p_{ij} = 0, & & \text{其它.} \end{cases}$$

由上可看出, 当质点位置 $i < 0$, 即在原点左边时, $p_{i,i-1} < \frac{1}{2}, p_{i,i+1} > \frac{1}{2}$, 此时质点下一步向右移动比向左移动的概率大, 且与离原点的距离成正比. 反之亦然. 当质点在原点时, 向左向右的概率相等. 这样的随机游动可作如下两种物理解释.

1° 考虑一容器内有 $2a$ 个粒子作随机游动. 设想一个薄膜 (界面) 将容器分为相等的左、右两部分 A 和 B. 如用 X_n 表示 n 时刻 B 内的粒子数与 A 内粒子数之差, 并假定每次移动只有两种可能, 一粒子从左到右或一粒子从右到左, (即同一时刻有两个或两个以上粒子移动的概率为 0, 当 $\Delta t \rightarrow 0$ 时作这种假设是合理的). 则 $\{X_n, n \geq 0\}$ 可用上述模型来描述.

2° 设一粒子受一“弹簧力”作用, 在直线上作随机游动, 当粒子偏离原点时, 受到一附加的与偏离距离成正比且指向原点的力的作用, 从而使向原点移动的概率增大. 用 X_n 表示粒子在时刻 n 的位置, 则同样可用上述模型来描述.

3.1 定义与例子

(3). 排队模型

(a) 离散排队系统

考虑顾客到达一服务台排队等待服务的情况. 若服务台前至少有一顾客等待, 则在一单位时间周期内, 服务员完成一个顾客的服务后, 该顾客立即离去; 若服务台前没有顾客, 则服务员空闲. 在一个服务周期内, 顾客可以到达, 设第 n 个周期到达的顾客数 ξ_n 是一个取值为非负整数的随机变量, 且 $\{\xi_n, n \geq 1\}$ 相互独立同分布. 在每个周期开始时系统的状态定义为服务台前等待服务的顾客数. 若现在状态为 i , 则下周期的状态 j 应为

$$j = \begin{cases} (i-1) + \xi, & i \geq 1, \\ \xi, & i = 0. \end{cases}$$

其中 ξ 为该周期内到达的顾客数. 记第 n 周期开始的顾客数为 X_n , 则 $X_{n+1} = (X_n - 1)^+ + \xi_n$, 这里 $a^+ = \max(a, 0)$. 根据马氏链的定义, 容易证明 $\{X_n, n \geq 0\}$ 是一个马氏链. 若设 $P\{\xi_n = k\} = a_k, a_k \geq 0, \sum_{k=0}^{\infty} a_k = 1$, 则 $\{X_n, n \geq 0\}$ 的转移概率为

$$\begin{cases} p_{0j} = a_j, & j \geq 0, \\ p_{1j} = a_j, & j \geq 0, \\ p_{ij} = a_{j+1-i}, & i > 1, j \geq i-1, \\ p_{ij} = 0, & i > 1, j < i-1. \end{cases}$$

直观上显而易见: 若 $E\xi_n = \sum_{k=0}^{\infty} k a_k > 1$, 则当 n 充分大后, 等待顾客的队长将无限增大; 若 $E\xi_n < 1$, 则等待服务的顾客队长趋近某种平衡.

(b) G/M/1 排队系统

G—表示顾客到达服务台的时间间隔, 假设为独立同分布, 分布函数为 $G(x)$;

M—表示服务时间, 假设为独立同指数分布 (设参数为 μ), 且与顾客到达过程相互独立;

1—表示单个服务员.

记 X_n 表示第 n 个顾客到达服务台时系统内的顾客数 (包括该顾客), T_n 表示第 n 个顾客到达时刻. 易证 $\{X_n, n \geq 1\}$ 为一马氏链. 下面计算它的转移概率. 令

$$\begin{aligned} A &\triangleq \{X_n = i, X_{n+1} = i+1-j\} \quad (i \geq 0, 0 \leq j \leq i) \\ &= \{X_n = i, \text{ 在 } (T_n, T_{n+1}] \text{ 时间服务完 } j \text{ 个顾客}\}. \end{aligned}$$

由于各顾客的服务时间相互独立, 且服从参数为 μ 的指数分布, 所以 $(0, t]$ 时间内服务完的顾客数服从参数为 μ 的 Poisson 分布. 即

$$P\{\text{在 } (0, t] \text{ 内服务完 } j \text{ 个顾客}\} = \frac{e^{-\mu t} (\mu t)^j}{j!}.$$

由此可得

$$P\{A|X_n = i\} = \int_0^{+\infty} P\{A|X_n = i, T_{n+1} - T_n = t\} dG(t) = \int_0^{+\infty} e^{-\mu t} \cdot \frac{(\mu t)^j}{j!} dG(t).$$

即

$$p_{i,i+1-j} = \int_0^{+\infty} e^{-\mu t} \frac{(\mu t)^j}{j!} dG(t), \quad 1 \leq j \leq i, i \geq 0.$$

p_{i0} 是服务台由有 i 个顾客转为空闲的概率, 显然

$$p_{i0} = \sum_{k=i+1}^{\infty} \int_0^{+\infty} e^{-\mu t} \frac{(\mu t)^k}{k!} dG(t) = \int_0^{+\infty} \sum_{k=i+1}^{\infty} e^{-\mu t} \frac{(\mu t)^k}{k!} dG(t), \quad i \geq 0.$$

(4). 离散分支过程

考虑某一群体, 假定某一代的每一个个体可以产生 ξ 个下一代个体, 其中 ξ 是取值为非负整数的离散随机变量, $P\{\xi = k\} = a_k \geq 0, k \geq 0, \sum_{k=0}^{\infty} a_k = 1$. 设某一代各个体产生下一代的个数相互独立同分布且与上代相互独立. 记 X_n 表示第 n 代个体的数目, 则当 $X_n = 0$ 时, 有 $X_{n+1} = 0$; 当 $X_n > 0$ 时, 有

$$X_{n+1} = \xi_1 + \xi_2 + \cdots + \xi_{X_n}.$$

其中 ξ_i 是第 n 代中第 i 个个体产生的下一代的个数. 由此可知, 只要给定 X_n , 那么 X_{n+1} 的分布就完全决定了, 且与以前的 X_{n-1}, X_{n-2}, \cdots 无关, 故 $\{X_n, n \geq 1\}$ 是一马氏链. 易知

$$\begin{aligned} p_{ij} &= P\{X_{n+1} = j | X_n = i\} = P\{\xi_1 + \xi_2 + \cdots + \xi_{X_n} = j | X_n = i\} \\ &= P\{\xi_1 + \xi_2 + \cdots + \xi_i = j\} \\ &= \frac{\partial^j (\sum_{k=0}^{\infty} a_k x^k)^i}{j! \partial x^j} \Big|_{x=0} \end{aligned}$$

最后一个等号的证明留给读者。(提示: 用母函数)

下面的定理提供了一个非常有用的获得马尔可夫链的方法, 并可用于检验一随机过程是否为马尔可夫链, 读者可以用前面的有关例子验证.

定理 3.1.1 设随机过程 $\{X_n, n \geq 0\}$ 满足:

- 1° $X_n = f(X_{n-1}, \xi_n)$ ($n \geq 0$), 其中 $f: S \times S \rightarrow S$, 且 ξ_n 取值在 S 上;
- 2° $\{\xi_n, n \geq 1\}$ 为独立同分布随机变量, 且 X_0 与 $\{\xi_n, n \geq 1\}$ 也相互独立;

则 $\{X_n, n \geq 0\}$ 是马尔可夫链, 而且其一步转移概率为

$$p_{ij} = P(f(i, \xi_1) = j). \quad (3.1.2)$$

3.2 转移概率矩阵

证：设 $n \geq 1$, 注意到 ξ_{n+1} 与 X_0, X_1, \dots, X_n 相互独立, 我们有

$$\begin{aligned} P(X_{n+1} = i_{n+1} | X_0 = i_0, \dots, X_n = i_n) \\ &= P(f(X_n, \xi_{n+1}) = i_{n+1} | X_0 = i_0, \dots, X_n = i_n) \\ &= P(f(i_n, \xi_{n+1}) = i_{n+1} | X_0 = i_0, \dots, X_n = i_n) \\ &= P(f(i_n, \xi_{n+1}) = i_{n+1}), \end{aligned}$$

同样地

$$P(X_{n+1} = i_{n+1} | X_n = i_n) = P(f(i_n, \xi_{n+1}) = i_{n+1}). \quad (3.1.3)$$

因此

$$P(X_{n+1} = i_{n+1} | X_0 = i_0, \dots, X_n = i_n) = P(X_{n+1} = i_{n+1} | X_n = i_n),$$

即 $\{X_n, n \geq 0\}$ 是马尔可夫链. 由 (3.1.3) 式知, 一步转移概率为 (3.1.2) 式. \square

§ 3.2 转移概率矩阵

设 $\{X_n, n \geq 0\}$ 为马氏链, $\mathbf{P} = (p_{ij})$, 其中 $p_{ij} = P\{X_{n+1} = j | X_n = i\}$ 是一步转移概率. 显然

$$p_{ij} \geq 0, i, j \in S; \sum_{j \in S} p_{ij} = 1, i \in S.$$

定义 称矩阵 $\mathbf{A} = (a_{ij})_{S \times S}$ 为 **随机矩阵**, 若 $a_{ij} \geq 0, i, j \in S$, 且对 $\forall i \in S$, 有 $\sum_{j \in S} a_{ij} = 1$. \square

显然, $\mathbf{P} = (p_{ij})$ 是一随机矩阵.

记

$$\pi_i(n) = P(X_n = i), \quad \pi(n) = (\pi_1(n), \pi_2(n), \dots, \pi_i(n) \dots),$$

$\pi(n)$ 表示 n 时刻 X_n 的概率分布向量. 称 $\{\pi_i(0), i \in S\}$ 为马氏链的初始分布. 下面, 我们将看到, 一个马氏链的特性完全由它的一步转移概率矩阵 \mathbf{P} 及初始分布向量 $\pi(0)$ 决定.

首先, 对任意 $i_0, i_1, \dots, i_n \in S$, 我们计算有限维联合分布 $P(X_0 = i_0, X_1 = i_1, \dots, X_n = i_n)$. 由概率的乘法公式及马氏性可知:

$$\begin{aligned} P(X_0 = i_0, X_1 = i_1, \dots, X_n = i_n) \\ &= P(X_0 = i_0)P(X_1 = i_1 | X_0 = i_0)P(X_2 = i_2 | X_0 = i_0, X_1 = i_1) \\ &\quad \cdots P(X_n = i_n | X_0 = i_0, \dots, X_{n-1} = i_{n-1}) \\ &= P(X_0 = i_0)P(X_1 = i_1 | X_0 = i_0) \overset{69}{P}(X_2 = i_2 | X_1 = i_1) \cdots P(X_n = i_n | X_{n-1} = i_{n-1}) \\ &= \pi_{i_0}(0)p_{i_0 i_1}p_{i_1 i_2} \cdots p_{i_{n-1} i_n}. \end{aligned}$$

故

$$P(X_0 = i_0, X_1 = i_1, \dots, X_n = i_n) = \pi_{i_0}(0) p_{i_0 i_1} p_{i_1 i_2} \cdots p_{i_{n-1} i_n}. \quad (3.2.1)$$

即 $P(X_0 = i_0, X_1 = i_1, \dots, X_n = i_n)$ 完全由 $\pi(0)$ 及 \mathbf{P} 决定.

类似可以证明任意 n 个时刻的联合分布也完全由 $\pi(0)$ 及 \mathbf{P} 决定.

其次, 有以下定理:

定理 3.2.1

$$\pi(n+1) = \pi(n)\mathbf{P}. \quad (3.2.2)$$

$$\pi(n) = \pi(0) \cdot \mathbf{P}^n. \quad (3.2.3)$$

其中 \mathbf{P}^n 是 \mathbf{P} 的 n 次幂.

证: 先对事件进行分解

$$(X_{n+1} = j) = \bigcup_{i \in S} (X_n = i, X_{n+1} = j).$$

因为当 $i \neq k$ 时, $(X_n = i) \cap (X_n = k) = \emptyset$. 故

$$\begin{aligned} P(X_{n+1} = j) &= \sum_{i \in S} P(X_n = i, X_{n+1} = j) \\ &= \sum_{i \in S} P(X_n = i) P(X_{n+1} = j | X_n = i) = \sum_{i \in S} \pi_i(n) \cdot p_{ij}. \end{aligned}$$

写成向量形式即得

$$\pi(n+1) = \pi(n)\mathbf{P}.$$

重复利用 (3.2.2) 式即得 (3.2.3) 式. □

(3.2.3) 式表明任一时刻分布由 $\pi(0)$ 及 \mathbf{P} 完全决定.

这些事实表明, 马氏链 $\{X_n, n > 0\}$ 的概率性质完全由 $\pi(0)$ 与 \mathbf{P} 的代数性质决定.

为了下述定理的书写方便, 记 $p_{ij}^{(m)} = P(X_{n+m} = j | X_n = i)$ 为 m 步转移概率;

$\mathbf{P}^{(m)} = (p_{ij}^{(m)})$ 为 m 步转移概率矩阵.

定理 3.2.2 (Chapman-Kolmogorov 方程)

$$p_{ij}^{(m+n)} = \sum_{k \in S} p_{ik}^{(m)} p_{kj}^{(n)} \quad (3.2.4)$$

或

$$\mathbf{P}^{(m+n)} = \mathbf{P}^{m+n} = \mathbf{P}^m \cdot \mathbf{P}^n = \mathbf{P}^{(m)} \cdot \mathbf{P}^{(n)} \quad (3.2.5)$$

证: 因

70

$$(X_0 = i, X_{m+n} = j) = \bigcup_{k \in S} (X_0 = i, X_m = k, X_{n+m} = j),$$

3.3 状态的分类

故

$$\begin{aligned}
 P(X_{m+n} = j | X_0 = i) &= \sum_{k \in S} P(X_0 = i, X_m = k, X_{m+n} = j) / P(X_0 = i) \\
 &= \sum_{k \in S} P(X_m = k | X_0 = i) \cdot P(X_{m+n} = j | X_0 = i, X_m = k) \\
 &= \sum_{k \in S} p_{ik}^{(m)} P(X_{m+n} = j | X_m = k) \quad (\text{由马氏性}) \\
 &= \sum_{k \in S} p_{ik}^{(m)} \cdot p_{kj}^{(n)}.
 \end{aligned}$$

即

$$p_{ij}^{(m+n)} = \sum_{k \in S} p_{ik}^{(m)} p_{kj}^{(n)}.$$

写成向量形式即

$$\mathbf{P}^{(m+n)} = \mathbf{P}^{(m)} \cdot \mathbf{P}^{(n)}.$$

再注意到 $\mathbf{P}^{(1)} = \mathbf{P}$, 将 $m = n = 1$ 代入上式得 $\mathbf{P}^{(2)} = \mathbf{P} \cdot \mathbf{P} = \mathbf{P}^2$. 从而得到 (3.2.4) 式及 (3.2.5) 式. \square

由上可知, 一个马氏链运动规律的概率特性取决于它的转移概率矩阵特性. 这样, 研究前者就可以转化为研究后者.

(3.2.4) 式简称 C-K 方程. 显然 $\mathbf{P}^{(m)} = (p_{ij}^{(m)})$ 是一随机矩阵.

§ 3.3 状态的分类

这一节我们将对马氏链的状态按其概率特性进行分类, 并讨论这些分类的判断准则. 先举例说明.

例 1 设系统有三种可能状态 $S = \{1, 2, 3\}$. “1” 表示系统运行良好, “2” 表示运行正常, “3” 表示系统失效. 以 X_n 表示系统在时刻 n 的状态, 并设 $\{X_n, n \geq 0\}$ 是一马氏链. 在没有维修及更换条件下, 其自然转移概率矩阵为

$$\mathbf{P} = \begin{bmatrix} \frac{17}{20} & \frac{2}{20} & \frac{1}{20} \\ 0 & \frac{9}{10} & \frac{1}{10} \\ 0 & 0 & 1 \end{bmatrix}.$$

由 \mathbf{P} 可以看出, 从 “1” 或 “2” 状态出发经有限次转移后总要到达 “3” 状态, 而一旦到达 “3” 则永远停在 “3”. 显然状态 “1”, “2” 与状态 “3” 概率性质不同. 由此我们引入如下定义:

定义 称状态 $i \in S$ 为 **吸收态**, 若 $p_{ii} = 1$. \square

定义 对 $i, j \in S$, 若存在 $n \in \mathbb{N}$, 使 $p_{ij}^{(n)} > 0$, 则称自状态 i 出发可达状态 j , 记为 $i \rightarrow j$. 如果 $i \rightarrow j$ 且 $j \rightarrow i$, 则称 i, j **相通**, 记为 $i \leftrightarrow j$. 若一马氏链的任意两个状态都相通, 则称为不可约链. \square

定义 首达时间为

$$T_{ij} = \min\{n : n \geq 1, X_n = j, X_0 = i\}.$$

若右边为空集, 则令 $T_{ij} = \infty$. \square

T_{ij} 表示从 i 出发首次到达 j 的时间; T_{ii} 表示从 i 出发首次回到 i 的时间.

定义 首达概率为

$$f_{ij}^{(n)} = P\{T_{ij} = n | X_0 = i\} = P\{X_n = j, X_k \neq j, 1 \leq k \leq n-1 | X_0 = i\}. \quad \square$$

$f_{ij}^{(n)}$ 表示从 i 出发经 n 步首次到达 j 的概率. 而 $f_{ij} = \sum_{n=1}^{\infty} f_{ij}^{(n)}$ 表示由 i 出发, 经有限步终于到达 j 的概率.

定义 若 $f_{ii} = 1$, 称 i 为 **常返状态**; 若 $f_{ii} < 1$, 称 i 为 **非常返状态**(或称为瞬时状态). \square

本节例 1 中, T_{13} 表示系统的工作寿命, 因此

$$f_{13}^{(1)} = P\{T_{13} = 1 | X_0 = 1\} = P_{13} = \frac{1}{20}.$$

因

$$(T_{13} = 2) = (1 \xrightarrow{(1)} 1 \xrightarrow{(1)} 3) \bigcup (1 \xrightarrow{(1)} 2 \xrightarrow{(1)} 3),$$

这里 $(1 \xrightarrow{(1)} 1 \xrightarrow{(1)} 3)$ 表示从“1”出发经 1 步到“1”, 再经 1 步到“3”. 故

$$f_{13}^{(2)} = p_{11} \cdot p_{13} + p_{12} \cdot p_{23} = \frac{21}{400}, \dots \text{等等}.$$

$P(T_{13} \geq n)$ 表示系统在 $[0, n]$ 内运行的可靠性. 故研究 $f_{ij}^{(n)}$ 及 T_{ij} 的特性是颇有意义的.

显然, 该系统至多经有限步总会被吸收态吸收, 因此由概率背景可直观地得到

$$\lim_{n \rightarrow \infty} \mathbf{P}^{(n)} = \begin{bmatrix} 0 & 0 & 1 \\ 0 & 0 & 1 \\ 0 & 0 & 1 \end{bmatrix}.$$

由此人们想到了利用概率背景来解决数学分析与代数问题等, 这就是现代随机分析所研究的内容.

当 $f_{ii} = 1$ 时, $\{f_{ii}^{(n)}, n \geq 1\}$ 是一概率分布, 有以下定义:

定义 如果 $f_{ii} = 1$, 记 $\mu_i = \sum_{n=1}^{\infty} n \cdot f_{ii}^{(n)}$, 则 μ_i 表示从 i 出发再回到 i 的平均回转时间. 若 $\mu_i < \infty$, 称 i 为 **正常返态**; 若 $\mu_i = \infty$, 称 i 为 **零常返态**. \square

3.3 状态的分类

定义 如果集合 $\{n : n \geq 1, p_{ii}^{(n)} > 0\} \neq \emptyset$, 称该数集的最大公约数 $d(i)$ 为状态 i 的周期. 若 $d(i) > 1$, 称 i 为周期的, 若 $d(i) = 1$, 称 i 为非周期的. \square


例如在 § 3.1 的例 (2)(a) 无限制随机游动中, 当 $r = 0, 0 < p < 1$ 时, $S = \{\dots, -1, 0, 1, 2, \dots\}$, $\{n : n \geq 1, p_{00}^{(n)} > 0\} = \{2, 4, 6, \dots\}$. 即状态 0 的 $d(0) = 2$, 即从 0 状态出发须经 2 的整数倍次游动才能回到 0 状态, 故它是周期的, 且周期为 2. 当 $p, q, r > 0$ 且 $p + q + r = 1$ 时, $\{n : n \geq 1, p_{00}^{(n)} > 0\} = \{1, 2, 3, \dots\}$, $d(0) = 1$, 故此时 0 状态是非周期的.

定义 若状态 i 为正常返的且非周期的, 则称 i 为 **遍历状态**. \square

例 2 设马氏链的 $S = \{1, 2, 3, 4\}$, 转移概率矩阵为:

$$P = \begin{bmatrix} \frac{1}{2} & \frac{1}{2} & 0 & 0 \\ 1 & 0 & 0 & 0 \\ 0 & \frac{1}{3} & \frac{2}{3} & 0 \\ \frac{1}{2} & 0 & \frac{1}{2} & 0 \end{bmatrix}.$$

该链各状态的转移如下图所示:



图示

因为

$$\begin{aligned} f_{44}^{(n)} &= 0, n \geq 1, \quad f_{44} = 0 < 1, \\ f_{33}^{(1)} &= \frac{2}{3}, \quad f_{33}^{(n)} = 0, n \geq 2, \quad f_{33} = \frac{2}{3} < 1, \end{aligned}$$

故状态 4 和 3 非常返; 由

$$\begin{aligned} f_{11} &= f_{11}^{(1)} + f_{11}^{(2)} = 1, \\ f_{22} &= \sum_{n=1}^{\infty} f_{22}^{(n)} = 0 + \frac{1}{2} + \frac{1}{4} + \frac{1}{8} + \dots = 1, \\ \mu_1 &= \sum_{n=1}^{\infty} n \cdot f_{11}^{(n)} = 1 \times \frac{1}{2} + 2 \times \frac{1}{2} = \frac{3}{2} < \infty, \\ \mu_2 &= \sum_{n=1}^{\infty} n \cdot f_{22}^{(n)} = 1 \times 0 + 2 \times \frac{1}{2} + \dots + n \cdot \frac{1}{2^{n-1}} + \dots = 3 < \infty, \end{aligned}$$

故状态 1 和 2 都是正常返的, 且易知它们是非周期的, 从而是遍历状态.

下面讨论各状态的若干性质以及如何利用转移概率矩阵 \mathbf{P} 来判断是否为常返状态.

$p_{ij}^{(n)}$ 与 $f_{ij}^{(n)}$ 有以下关系:

定理 3.3.1 对 $\forall i, j \in S, n \geq 1$, 有

1°

$$p_{ij}^{(n)} = \sum_{l=1}^n f_{ij}^{(l)} p_{jj}^{(n-l)}, \quad (3.3.1)$$

2°

$$f_{ij}^{(n)} = \sum_{k \neq j} p_{ik} f_{kj}^{(n-1)} I_{(n>1)} + p_{ij} I_{(n=1)}, \quad (3.3.2)$$

3°

$$i \rightarrow j \Leftrightarrow f_{ij} > 0, \quad (3.3.3)$$

$$i \leftrightarrow j \Leftrightarrow f_{ij} > 0 \text{ 且 } f_{ji} > 0. \quad (3.3.4)$$

证: 1° 因为

$$\begin{aligned} \{X_0 = i, X_n = j\} &= \{X_0 = i, X_n = j\} \cap \left\{ \bigcap_{l=1}^{\infty} (T_{ij} = l) \right\} \\ &= \left\{ \bigcup_{l=1}^n (X_0 = i, X_n = j, T_{ij} = l) \right\} \cup \left\{ \bigcup_{l>n} (X_0 = i, X_n = j, T_{ij} = l) \right\}, \end{aligned}$$

而

$$\bigcup_{l>n} \{X_0 = i, X_n = j, T_{ij} = l\} = \emptyset,$$

所以

$$\{X_0 = i, X_n = j\} = \bigcup_{l=1}^n \{X_0 = i, X_n = j, T_{ij} = l\}.$$

于是

$$\begin{aligned} &P(X_0 = i) \cdot P(X_n = j | X_0 = i) \\ &= \sum_{l=1}^n P(X_0 = i) \cdot P(T_{ij} = l | X_0 = i) \cdot P(X_n = j | X_0 = i, T_{ij} = l), \end{aligned}$$

因此

$$\begin{aligned} &P(X_n = j | X_0 = i) \\ &= \sum_{l=1}^n P(T_{ij} = l | X_0 = i) \cdot P(X_n = j | X_0 = i, X_k \neq j, 1 \leq k \leq l-1, X_l = j) \\ &= \sum_{l=1}^n f_{ij}^{(l)} \cdot P(X_n = j | X_l = j) \quad (\text{由马氏性}) \\ &= \sum_{l=1}^n f_{ij}^{(l)} \cdot p_{jj}^{(n-l)}, \end{aligned}$$

3.3 状态的分类

即

$$p_{ij}^{(n)} = \sum_{l=1}^n f_{ij}^{(l)} p_{jj}^{(n-l)}.$$

2° 当 $n=1$ 时, 显然有 $f_{ij}^{(1)} = p_{ij}$. 下面考虑 $n>1$ 的情况.

由于

$$\{T_{ij} = n, X_0 = i\} = \bigcup_{k \neq j} \{X_n = j, X_1 = k, X_0 = i\},$$

因此有

$$P(X_0 = i)P(T_{ij} = n | X_0 = i) = \sum_{k \neq j} P(X_0 = i)P(X_1 = k | X_0 = i)P(X_n = j | X_1 = k, X_0 = i).$$

由马氏性得

$$f_{ij}^{(n)} = \sum_{k \neq j} p_{ik} f_{kj}^{(n-1)}.$$

综上, (3.3.2) 式成立.

3° 当 $i \rightarrow j$ 时, $\exists n > 0$, 使 $p_{ij}^{(n)} > 0$. 取 $n' = \min\{n : p_{ij}^{(n)} > 0\}$, 则

$$f_{ij}^{(n')} = P\{T_{ij} = n' | X_0 = i\} = p_{ij}^{(n')} > 0.$$

因此

$$f_{ij} = \sum_{n=1}^{\infty} f_{ij}^{(n)} \geq f_{ij}^{(n')} > 0.$$

即 $i \rightarrow j$ 时, $f_{ij} > 0$.

反之, 当 $f_{ij} > 0$ 时, $\exists n'$, 使 $f_{ij}^{(n')} > 0$, 从而 $p_{ij}^{(n')} > 0$, 得 $i \rightarrow j$. 综上所述

$$i \rightarrow j \Leftrightarrow f_{ij} > 0.$$

同理 $j \rightarrow i$ 时, 有: $j \rightarrow i \Leftrightarrow f_{ji} > 0$, 故

$$i \leftrightarrow j \Leftrightarrow f_{ij} > 0 \text{ 且 } f_{ji} > 0. \quad \square$$

定理 3.3.2 状态 i 为常返态, 当且仅当

$$\sum_{n=0}^{\infty} p_{ii}^{(n)} = \infty; \quad (3.3.5)$$

状态 i 为非常返态, 当且仅当

$$\sum_{n=0}^{\infty} p_{ii}^{(n)} = \frac{1}{1 - f_{ii}} < \infty. \quad (3.3.6)$$

证：约定 $p_{ii}^{(0)} = 1, f_{ii}^{(0)} = 0$. 由 (3.3.1) 式有

$$p_{ii}^{(n)} = \sum_{l=0}^n f_{ii}^{(l)} p_{ii}^{(n-l)}.$$

令 $\{p_{ii}^{(n)}\}, \{f_{ii}^{(n)}\} (i \geq 0)$ 的母函数分别为: $P(\rho), F(\rho)$. 即

$$P(\rho) = \sum_{n=0}^{\infty} p_{ii}^{(n)} \rho^n, \quad F(\rho) = \sum_{n=0}^{\infty} f_{ii}^{(n)} \rho^n.$$

又

$$\begin{aligned} \sum_{n=1}^{\infty} p_{ii}^{(n)} \rho^n &= \sum_{n=1}^{\infty} \left(\sum_{l=1}^n f_{ii}^{(l)} p_{ii}^{(n-l)} \right) \rho^n = \left(\sum_{l=1}^{\infty} f_{ii}^{(l)} \rho^l \right) \left(\sum_{n=l}^{\infty} p_{ii}^{(n-l)} \rho^{n-l} \right) \\ &= (F(\rho) - f_{ii}^{(0)}) \sum_{n'=0}^{\infty} p_{ii}^{(n')} \rho^{n'} = F(\rho) \cdot P(\rho) \quad (\text{因为 } f_{ii}^{(0)} = 0). \end{aligned}$$

而

$$\sum_{n=1}^{\infty} p_{ii}^{(n)} \rho^n = \sum_{n=0}^{\infty} p_{ii}^{(n)} \rho^n - p_{ii}^{(0)} \rho^0 = P(\rho) - 1.$$

因此

$$P(\rho) - 1 = P(\rho) \cdot F(\rho).$$

注意到, 当 $0 \leq \rho < 1$ 时, $F(\rho) < f_{ii} \leq 1$, 故

$$P(\rho) = \frac{1}{1 - F(\rho)}, \quad 0 \leq \rho < 1. \quad (3.3.7)$$

又因对一切 $0 \leq \rho < 1$ 及正整数 N , 有

$$\sum_{n=0}^N p_{ii}^{(n)} \rho^n \leq P(\rho) \leq \sum_{n=0}^{\infty} p_{ii}^{(n)}. \quad (3.3.8)$$

且当 $\rho \uparrow 1$ 时 $P(\rho)$ 不减, 故在 (3.3.8) 式中先令 $\rho \uparrow 1$, 后令 $N \rightarrow \infty$ 可得

$$\lim_{\rho \rightarrow 1^-} P(\rho) = \sum_{n=0}^{\infty} p_{ii}^{(n)}. \quad (3.3.9)$$

同理可得

$$\lim_{\rho \rightarrow 1^-} F(\rho) = \sum_{n=0}^{\infty} f_{ii}^{(n)} = f_{ii}. \quad (3.3.10)$$

于是在 (3.3.7) 式中两边令 $\rho \uparrow 1$, 由 (3.3.9) 式和 (3.3.10) 式便可得定理的结论. \square

为解释定理 3.3.2 的直观意义, 令

$$I_n(i) = \begin{cases} 1, & X_n = i, \\ 0, & X_n \neq i \end{cases}$$

3.3 状态的分类

及

$$S(i) = \sum_{n=0}^{\infty} I_n(i).$$

则 $S(i)$ 表示马氏链 $\{X_n, n \geq 0\}$ 到达 i 的次数. 于是

$$E\{S(i)|X_0 = i\} = \sum_{n=0}^{\infty} E(I_n(i)|X_0 = i) = \sum_{n=0}^{\infty} P\{X_n = i|X_0 = i\} = \sum_{n=0}^{\infty} p_{ii}^{(n)}. \quad (3.3.11)$$

可见 $\sum_{n=0}^{\infty} p_{ii}^{(n)}$ 表示由 i 出发返回到 i 的平均次数. 当 i 为常返态时, 返回 i 的平均次数为无限多次, 反之亦然. 当 i 为非常返态时, 再回到 i 的平均次数至多有限次.

推论 1 若 j 非常返, 则对任意 $i \in S$, 有

$$\sum_{n=1}^{\infty} p_{ij}^{(n)} < \infty. \quad (3.3.12)$$

$$\lim_{n \rightarrow \infty} p_{ij}^{(n)} = 0. \quad (3.3.13)$$

证: 由 (3.3.1) 式两边对 n 求和得

$$\begin{aligned} \sum_{n=1}^N p_{ij}^{(n)} &= \sum_{n=1}^N \sum_{l=1}^n f_{ij}^{(l)} p_{jj}^{(n-l)} = \sum_{l=1}^N \sum_{n=l}^N f_{ij}^{(l)} p_{jj}^{(n-l)} \\ &= \sum_{l=1}^N f_{ij}^{(l)} \sum_{m=0}^{N-l} p_{jj}^{(m)} \leq \sum_{l=1}^N f_{ij}^{(l)} \cdot \sum_{n=0}^N p_{jj}^{(n)}. \end{aligned}$$

令 $N \rightarrow \infty$, 则

$$\sum_{n=1}^{\infty} p_{ij}^{(n)} \leq \sum_{l=1}^{\infty} f_{ij}^{(l)} \left(1 + \sum_{n=1}^{\infty} p_{jj}^{(n)}\right) \leq 1 + \sum_{n=1}^{\infty} p_{jj}^{(n)} < \infty,$$

由此即得 (3.3.12) 式. 又因为 $p_{ij}^{(n)} \geq 0$, 所以 (3.3.13) 式也成立. \square

推论 2 若 j 为常返态, 则

1° 当 $i \rightarrow j$ 时, 有

$$\sum_{n=1}^{\infty} p_{ij}^{(n)} = \infty. \quad (3.3.14)$$

2° 当 $i \nrightarrow j$ 时 (不可达), 有

$$\sum_{n=1}^{\infty} p_{ij}^{(n)} = 0. \quad (3.3.15)$$

证: (3.3.15) 式显然成立, 下面证 (3.3.14) 式. 因 $i \rightarrow j$, 故 $\exists m > 0$, 使 $p_{ij}^{(m)} > 0$. 而

$$P_{ij}^{(m+n)} = \sum_{k \in S} p_{ik}^{(m)} p_{kj}^{(n)} \geq p_{ij}^{(m)} \cdot p_{jj}^{(n)},$$

故

$$\sum_{n=1}^{\infty} p_{ij}^{(m+n)} \geq p_{ij}^{(m)} \sum_{n=1}^{\infty} p_{jj}^{(n)} = \infty,$$

此即 (3.3.14) 式. □

下面再从概率意义考察常返性质. 记

$$S_m(j) = \sum_{n=m}^{\infty} I_n(j),$$

$$g_{ij} = P\{S_1(j) = +\infty | X_0 = i\} = P\{S_{m+1}(j) = +\infty | X_m = i\}.$$

事件 $\{S_m(j) = +\infty\}$ 表示从时刻 m 起系统无穷多次到达状态 j . 我们有:

定理 3.3.3 对任意 $i \in S$, 有

$$g_{ij} = \begin{cases} f_{ij}, & \text{如 } j \text{ 常返.} \\ 0, & \text{如 } j \text{ 非常返.} \end{cases} \quad (3.3.16)$$

证: 因 $\{S_m(j) \geq k+1\} \subset \{S_m(j) \geq k\}$, 故

$$(S_1(j) = +\infty) = \bigcap_{k=1}^{\infty} \{S_1(j) \geq k\} = \lim_{k \rightarrow \infty} \{S_1(j) \geq k\}.$$

由概率的连续性可得

$$g_{ij} = P\{S_1(j) = +\infty | X_0 = i\} = P\left\{\bigcap_{k=1}^{\infty} (S_1(j) \geq k) | X_0 = i\right\} = \lim_{k \rightarrow \infty} P\{S_1(j) \geq k | X_0 = i\}. \quad (3.3.17)$$

又

$$\{S_1(j) \geq k+1, X_0 = i\} = \bigcup_{l=1}^{\infty} \{T_{ij} = l, S_1(j) \geq k+1\} = \bigcup_{l=1}^{\infty} \{T_{ij} = l, S_{l+1}(j) \geq k\}.$$

故

$$\begin{aligned} P\{S_1(j) \geq k+1 | X_0 = i\} &= \sum_{l=1}^{\infty} P\{T_{ij} = l | X_0 = i\} P\{S_{l+1}(j) \geq k | X_0 = i, T_{ij} = l\} \\ &= \sum_{l=1}^{\infty} f_{ij}^{(l)} P\{S_{l+1}(j) \geq k | X_0 = i, X_m \neq j, 1 \leq m \leq l-1, X_l = j\} \\ &= \sum_{l=1}^{\infty} f_{ij}^{(l)} P\{S_{l+1}(j) \geq k | X_l = j\} \quad (\text{由马氏性}) \\ &= \sum_{l=1}^{\infty} f_{ij}^{(l)} P\{S_1(j) \geq k | X_0 = j\}. \quad (\text{由时齐性}) \end{aligned}$$

即

$$P\{S_1(j) \geq k+1 | X_0 = i\} = f_{ij} P\{S_1(j) \geq k | X_0 = j\}. \quad (3.3.18)$$

3.3 状态的分类

反复利用上式可得

$$P\{S_1(j) \geq k+1 | X_0 = i\} = f_{ij}(f_{jj})^k. \quad (3.3.19)$$

令 $k \rightarrow \infty$, 若 j 常返, 即 $f_{jj} = 1$, 则由 (3.3.17) 及 (3.3.19) 得

$$g_{ij} = f_{ij},$$

若 j 非常返, 即 $f_{jj} < 1$, 则

$$g_{ij} = 0. \quad \square$$

定理 3.3.4 状态 i 常返, 当且仅当 $g_{ii} = 1$; 若状态 i 非常返, 则 $g_{ii} = 0$.

证: 将 (3.3.16) 式中 j 换成 i 即可得. \square

定理 3.3.4 的说明: 若 i 常返, 则系统从 i 出发以概率 1 无穷多次返回 i , 即从 i 出发的几乎所有样本轨道无穷多次回到 i . 若 i 非常返, 则从 i 出发几乎所有样本轨道至多有限次回到 i .

进一步地, 若 i 为常返态, 如何判别它是零常返的或遍历的? 我们有以下的重要定理.

定理 3.3.5 设 $\{X_n, n \geq 0\}$ 是一常返的马氏链 (即状态空间 S 是单一的常返类), 则对于任意的 $i, j \in S$, 有

$$\lim_{n \rightarrow \infty} \frac{1}{n+1} \sum_{k=0}^n p_{ij}^{(k)} = \frac{1}{\mu_{ij}}, \quad (3.3.20)$$

下面利用实分析的一个结果, 来证明该定理。

引理 3.3.1 设幂级数 $\sum_{n=0}^{\infty} a_n z^n$ 在 $0 \leq z < 1$ 收敛, a_n 非负, 记

$$A(z) = \sum_{n=0}^{\infty} a_n z^n, 0 \leq z < 1$$

则

$$\lim_{n \rightarrow \infty} \frac{1}{n+1} \sum_{k=0}^n a_k = \lim_{z \rightarrow 1-0} (1-z)A(z). \quad (3.3.21)$$

这个引理由 Hardy 与 Littlewood 给出, 有兴趣的读者可参见 E.C.Titchmarsh 的《函数论》(中译本)。

定理 3.3.5 的证明 把 $P_{ij}(z) = \sum_{n=0}^{\infty} p_{ij}^{(n)} z^n$ 作为引理 3.3.1 中的 $A(z)$, 于是由 (3.3.21)

$$\lim_{n \rightarrow \infty} \frac{1}{n+1} \sum_{k=0}^n p_{ij}^{(k)} = \lim_{z \rightarrow 1-0} (1-z)P_{ij}(z).$$

由定理 3.3.2 的证明知, 对 $i \neq j$ 有

$$P_{ij}(z) = F_{ij}(z)P_{jj}(z) = \frac{F_{ij}(z)}{1 - F_{jj}(z)}.$$

因此, 对 $i \neq j$ 有

$$\lim_{z \rightarrow 1-0} (1-z)P_{ij}(z) = \lim_{z \rightarrow 1-0} \frac{1-z}{1-F_{jj}(z)} \cdot F'_{ij}(z).$$

因为 $\lim_{z \rightarrow 1-0} F_{ij}(z) = F_{ij}(1) = f_{ij} = 1$, 所以

$$\lim_{z \rightarrow 1-0} (1-z)P_{ij}(z) = \lim_{z \rightarrow 1-0} \frac{1-z}{1-F_{jj}(z)}.$$

这个结果显然对 $i = j$ 亦成立. 而由洛必大法则有

$$\lim_{z \rightarrow 1-0} \frac{1-z}{1-F_{jj}(z)} = \lim_{z \rightarrow 1-0} \frac{-1}{-F'_{jj}(z)} = \frac{1}{F'_{jj}(1)}$$

而

$$F'_{jj}(1) = \sum_{k=0}^{\infty} k f_{jj}^{(k)} = \mu_{jj}. \quad \square$$

由分析中的结果易知, 若极限 $\lim_{n \rightarrow \infty} p_{ii}^{(n)}$ 存在, 则有

$$\lim_{n \rightarrow \infty} p_{ii}^{(n)} = \lim_{n \rightarrow \infty} \frac{1}{n+1} \sum_{k=0}^n p_{ii}^{(k)}$$

由此及定理 3.3.5 不难得到:

定理 3.3.6 设 i 常返且周期为 d , 则

$$\lim_{n \rightarrow \infty} p_{ii}^{(nd)} = \frac{d}{\mu_i} \quad (3.3.22)$$

其中 μ_i 为 i 的平均回转时间. 当 $\mu_i = +\infty$ 时, 理解为 $\frac{d}{\mu_i} = 0$. \square

证明 类似定理 3.3.5 的证明, 只须令 $y = x^d$, 对 $P_{ij}(y)$ 用引理 3.3.1 且考虑到 $i = j$ 时便可得 (3.3.22) 式.

定理 3.3.7 设 i 常返, 则

1° i 为零常返, 当且仅当

$$\lim_{n \rightarrow \infty} p_{ii}^{(n)} = 0,$$

2° i 为遍历, 当且仅当

$$\lim_{n \rightarrow \infty} p_{ii}^{(n)} = \frac{1}{\mu_i} > 0. \quad (3.3.23)$$

证: 1° 若 i 零常返, 则由 (3.3.22) 知 $\lim_{n \rightarrow \infty} p_{ii}^{(nd)} = 0$. 由周期的定义知, 当 n 不能被 d 整除 (即 $n \neq 0 \pmod{d}$) 时, $p_{ii}^{(n)} = 0$. 故有

$$\lim_{n \rightarrow \infty} p_{ii}^{(n)} = 0.$$

反之, 若 $\lim_{n \rightarrow \infty} p_{ii}^{(n)} = 0$, 假设 i 是正常返, 由 (3.3.22) 式知 $\lim_{n \rightarrow \infty} p_{ii}^{(nd)} > 0$, 矛盾. 故 i 是零常返.

3.3 状态的分类

2° 设 $\lim_{n \rightarrow \infty} p_{ii}^{(n)} = \frac{1}{\mu_i} > 0$, 由 1° 知 i 必为正常返, 且 $\lim_{n \rightarrow \infty} p_{ii}^{(nd)} = \frac{1}{\mu_i}$, 与 (3.3.22) 比较得 $d = 1$, 故 i 遍历. 反之, 由定理 3.3.6 即得. \square

状态相通关系为等价关系, 因为具有

1° 自反性: $i \leftrightarrow i$. 这由下面定义可得

$$p_{ij}^{(0)} = \delta_{ij} = \begin{cases} 1, & j = i, \\ 0, & j \neq i. \end{cases}$$

2° 对称性: 若 $i \leftrightarrow j$, 则 $j \leftrightarrow i$.

3° 传递性: 若 $i \leftrightarrow j$ 且 $j \leftrightarrow k$, 则 $i \leftrightarrow k$.

传递性的证明如下: 由于 $i \leftrightarrow j, j \leftrightarrow k$, 则 $\exists m, n$, 使 $p_{ij}^{(m)} > 0, p_{jk}^{(n)} > 0$, 则

$$p_{ik}^{(m+n)} = \sum_{l \in S} p_{il}^{(m)} p_{lk}^{(n)} \geq p_{ij}^{(m)} \cdot p_{jk}^{(n)} > 0.$$

故 $i \rightarrow k$. 同理可证 $k \rightarrow i$. 故 $i \leftrightarrow k$. \square

利用等价关系, 可以把马氏链的状态空间分为若干等价类. 在同一等价类内的状态彼此相通; 在不同的等价类中的状态不可能彼此相通. 然而, 从某一类出发以正的概率到达另一类的情形是可能的. 由上知对于不可约链, 又有以下的定义:

定义 如一马氏链的所有状态属于同一等价类, 则称它是 **不可约链**. \square

为说明这些概念, 考虑下面几个例子.

例 3

(a)

$$S = \{1, 2, 3\}, \quad \mathbf{P} = \begin{bmatrix} \frac{1}{2} & \frac{1}{4} & \frac{1}{4} \\ \frac{1}{4} & 0 & \frac{3}{4} \\ 0 & \frac{2}{3} & \frac{1}{3} \end{bmatrix};$$

(b)


$$S = \{1, 2, 3, 4, 5\}, \quad \mathbf{P} = \begin{bmatrix} \frac{1}{2} & \frac{1}{2} & 0 & 0 & 0 \\ \frac{1}{4} & \frac{3}{4} & 0 & 0 & 0 \\ 0 & 0 & 0 & 1 & 0 \\ 0 & 0 & \frac{1}{2} & 0 & \frac{1}{2} \\ 0 & 0 & 0 & 1 & 0 \end{bmatrix};$$

(c)

$$S = \{1, 2, 3, 4, 5\}, \quad \mathbf{P} = \begin{bmatrix} 0.6 & 0.1 & 0 & 0.3 & 0 \\ 0.2 & 0.5 & 0.1 & 0.2 & 0 \\ 0.2 & 0.2 & 0.4 & 0.1 & 0.1 \\ 0 & 0 & 0 & 1 & 0 \\ 0 & 0 & 0 & 0 & 1 \end{bmatrix}.$$


利用各种情况下的状态转移图进行判断.

(a) 由于所有状态相通 (见图 (a)), 组成一等价类. 故该链是不可约链.




(a)

(b) 此链可分为两个等价类 $\{1, 2\}$ 及 $\{3, 4, 5\}$ (见图 (b)).



(b)

(c) 此链可分为三个等价类 $\{1, 2, 3\}$, $\{4\}$ 及 $\{5\}$ (见图 (c)). 由 $\{1, 2, 3\}$ 可进入 $\{4\}$ 或 $\{5\}$, 反之则不行.



(c)

定理 3.3.8 如果 i 常返, 且 $i \rightarrow j$, 则 j 必常返, 且 $f_{ji} = 1$.

证: 先证对 $\forall i, j \in S$, 有 $0 \leq g_{ij} \leq f_{ij}$. 这是因为

$$\begin{aligned} \{T_{ij} \leq \infty\} &= \bigcup_{n=1}^{\infty} \{T_{ij} = n\} \\ &= \bigcup_{n=1}^{\infty} \{X_0 = i, X_l \neq j, 0 < l < n, X_n = j\} = \bigcup_{n=1}^{\infty} \{X_0 = i, X_n = j\}, \end{aligned}$$

而

$$\{X_0 = i, S_1(j) = +\infty\} = \bigcap_{m=1}^{\infty} \bigcup_{n=m}^{\infty} \{X_0 = i, X_n = j\} \subset \bigcup_{n=1}^{\infty} \{X_0 = i, X_n = j\},$$

3.3 状态的分类

故

$$0 \leq g_{ij} = P(S_1(j) = +\infty | X_0 = i) \leq P(T_{ij} < +\infty | X_0 = i) = f_{ij}.$$

因 $i \rightarrow j$, 存在 $m > 0$, 使 $p_{ij}^{(m)} > 0$, 又对 $\forall h \in S$,

$$\{X_0 = i, S_1(h) = +\infty\} = \bigcup_{k \in S} \{X_0 = i, X_m = k, S_{m+1}(h) = +\infty\},$$

有

$$g_{ih} = \sum_{k \in S} p_{ik}^{(m)} P(S_{m+1}(h) = +\infty | X_0 = i, X_m = k) = \sum_{k \in S} p_{ik}^{(m)} g_{kh}.$$

又因 i 为常返态, $f_{ii} = 1$ 故

$$0 = 1 - f_{ii} = \sum_{k \in S} p_{ik}^{(m)} - \sum_{k \in S} p_{ik}^{(m)} g_{ki} = \sum_{k \in S} p_{ik}^{(m)} (1 - g_{ki}) \geq p_{ij}^{(m)} (1 - g_{ji}) \geq 0.$$

从而 $1 = g_{ji} \leq f_{ji} \leq 1$, 得 $f_{ji} = 1$. 故 $j \rightarrow i$.

设 $p_{ji}^{(r)} = \alpha > 0, p_{ij}^{(s)} = \beta > 0$. 由 C-K 方程知, 对任意 $n \geq 0$, 有

$$p_{jj}^{(r+n+s)} \geq p_{ji}^{(r)} \cdot p_{ii}^{(n)} \cdot p_{ij}^{(s)} = \alpha \cdot \beta \cdot p_{ii}^{(n)}. \quad (3.3.24)$$

由 i 常返及定理 3.3.2, 有 $\sum_{n=1}^{\infty} p_{ii}^{(n)} = \infty$. 从而

$$\sum_{n=1}^{\infty} p_{jj}^{(n)} = +\infty.$$

故 j 常返. □

对于相通的状态, 有:

定理 3.3.9 若 $i \leftrightarrow j$, 则

1° i 与 j 同为常返或非常返. 若为常返, 则它们同为正常返或同为零常返;

2° i 与 j 或有相同的周期, 或同为非周期.

证: 1° 的前一部分是定理 3.3.8 的直接推论. 现设 j 为零常返, 由定理 3.3.7 有 $\lim_{n \rightarrow \infty} p_{jj}^{(n)} = 0$. 由 (3.3.24) 得 $\lim_{n \rightarrow \infty} p_{ii}^{(n)} = 0$, 故 i 也是零常返.

同理可证, 若 i 为零常返, 由

$$p_{ii}^{(r+n+s)} \geq p_{ij}^{(s)} \cdot p_{jj}^{(n)} \cdot p_{ji}^{(r)} = \beta \cdot \alpha \cdot p_{jj}^{(n)} \quad (3.3.25)$$


可知 j 也是零常返.

2° 仍令 $p_{ji}^{(r)} = \alpha > 0, p_{ij}^{(s)} = \beta > 0$, 设 i 的周期为 d , j 的周期为 t . 因此对 $\forall m \in \mathbb{N}, \exists n = mt$, 使得 $p_{jj}^{(n)} > 0$. 由 (3.3.25) 式知, $p_{ii}^{(n+r+s)} > 0$, 从而 $n+r+s$ 能被 d 整除. 但 $p_{ii}^{(r+s)} \geq p_{ij}^{(s)} \cdot p_{ji}^{(r)} = \alpha \cdot \beta > 0$, 所以 $r+s$ 也能被 d 整除. 可见, n 能被 d 整除. 故 t 能被 d 整除. 反之, 利用 (3.3.24) 类似可推得 d 能被 t 整除. 从而 $t=d$. □

该定理说明, 对相通的状态, 因是同类型, 故只需选出其中之一较容易判别的状态即可.

例 4 设马氏链 $S = \{1, 2, 3, \dots\}$, 转移概率为 $p_{11} = \frac{1}{2}, p_{ii+1} = \frac{1}{2}, p_{i1} = \frac{1}{2}, i \in S$. 分析状态 1.

由如下状态转移图易知:



图示

$$f_{11}^{(1)} = \frac{1}{2}, \quad f_{11}^{(2)} = \left(\frac{1}{2}\right)^2, \quad f_{11}^{(3)} = \left(\frac{1}{2}\right)^3, \quad \dots \quad f_{11}^{(n)} = \left(\frac{1}{2}\right)^n.$$

故

$$f_{11} = \sum_{n=1}^{\infty} \left(\frac{1}{2}\right)^n = 1,$$

所以“1”是常返态. 又

$$\mu_1 = \sum_{n=1}^{\infty} n \cdot \left(\frac{1}{2}\right)^n < \infty,$$

所以“1”是正常返态. 再由 $p_{11}^{(1)} = \frac{1}{2} > 0$, 知“1”是非周期的. 从而“1”是遍历的. 对其它 $i \neq 1$, 因 $i \leftrightarrow 1$, 故 i 也是遍历的 (若求 $f_{ii}^{(n)}$ 则较麻烦).

关于常返态的判断, 我们可以总结为以下重要定理:

定理 3.3.10 下列命题等价:

- 1° i 为常返态;
- 2° $P\{\bigcup_{n=1}^{\infty} (X_n = i) | X_0 = i\} = 1$;
- 3° $P(S_1(i) = +\infty | X_0 = i) = 1$;
- 4° $\sum_{n=0}^{\infty} p_{ii}^{(n)} = +\infty$;
- 5° $E\{S_1(i) | X_0 = i\} = +\infty$.

证: 1° \iff 2° : 由于 $f_{ii} = P(T_{ii} = \infty | X_0 = i) = 1$, 及

$$\begin{aligned} \{T_{ii} < \infty\} &= \bigcup_{n=1}^{\infty} \{T_{ii} = n\} \\ &= \bigcup_{n=1}^{\infty} \{X_0 = i, X_l \neq i, 0 < l < n, X_n = i\} = \bigcup_{n=1}^{\infty} \{X_0 = 1, X_n = i\}, \end{aligned}$$

3.3 状态的分类

因此

$$P\left\{\bigcup_{n=1}^{\infty}(X_n = i) \mid X_0 = i\right\} = P(T_{ii} < \infty \mid X_0 = i) = f_{ii} = 1,$$

即 1° 与 2° 等价.

$1^\circ \iff 3^\circ$: 见定理 3.3.4 .

$1^\circ \iff 4^\circ$: 见定理 3.3.2 .

$4^\circ \iff 5^\circ$: 由 (3.3.11) 式即得.

□

读者可自己对以上结论给出直观解释.

例 5 直线上无限制随机游动

设 $\{Y_n, n \geq 1\}$ i.i.d., $Y_0 = 0$, $P(Y_1 = 1) = p, P(Y_1 = -1) = q$, 令 $X_0 = 0$, $X_n = \sum_{i=1}^n Y_i$, 则 $\{X_n, n \geq 1\}$ 称为直线上无限制随机游动. 易知该马氏链的全体状态 $\{\dots, -2, -1, 0, 1, 2, \dots\}$ 构成一个类. 问题是: 它是常返类还是非常返类? 为此, 我们只需选一个代表 i 即可.

以下我们来计算 $\sum_n p_{ii}^{(n)}$, 据此来判别 i 是否常返. 易知:

$$p_{ii}^{(2n-1)} = 0$$

而

$$p_{ii}^{(2n)} = C_{2n}^n p^n q^n \quad (3.3.26)$$

考虑母函数

$$\begin{aligned} P_{ii}(z) &= \sum_{n=0}^{\infty} C_{2n}^n p^n q^n z^{2n} \\ &= \sum_{n=0}^{\infty} \frac{(2n)!}{n!n!} (pqz^2)^n \\ &= \sum_{n=0}^{\infty} \frac{2^{2n}(-1)^n}{n!} \left(-\frac{1}{2}\right) \left(-\frac{3}{2}\right) \cdots \left(-\frac{2n-1}{2}\right) (pqz^2)^n \\ &= \sum_{n=0}^{\infty} \frac{1}{n!} \left(-\frac{1}{2}\right) \left(-\frac{3}{2}\right) \cdots \left(-\frac{2n-1}{2}\right) (-4pqz^2)^n \\ &= (1 - 4pqz^2)^{-\frac{1}{2}} \end{aligned}$$

从而有

$$\sum_{n=0}^{\infty} p_{ii}^{(n)} = P_{ii}(1) = \lim_{z \rightarrow 1-0} P_{ii}(z) = \lim_{z \rightarrow 1-0} (1 - 4pqz^2)^{-\frac{1}{2}} = \begin{cases} \infty, p = \frac{1}{2} \\ \text{有限}, p \neq \frac{1}{2} \end{cases}$$

85

由此知, $p = \frac{1}{2}$ 时 i 是常返的, 从而全体状态构成单一的类是常返的; $p \neq \frac{1}{2}$ 时, 链是非常返的。

例 6 现在我们讨论平面上的对称随机游动. 质点的位置是平面上的整数格点 (坐标为整数的点). 每个位置有四个相邻的位置, 质点各以 $\frac{1}{4}$ 的概率转移到这四个相邻位置中的每一个. 易见平面上的对称游动是周期为 2 的不可约链.

我们来计算质点经过 $2n$ 步仍回原位置的概率 u_n . 这时质点必须与横坐标平行地向右移动 k 步, 向左也移动 k 步, 与纵坐标轴平行的向上移动 l 步, 向下也移动 l 步, 且 $k+l=n$. 因此

$$u_n = \frac{1}{4^{2n}} \sum_{k=0}^n \frac{(2n)!}{[k!(n-k)!]^2} = \frac{1}{4^{2n}} C_{2n}^n \sum_{k=0}^n (C_n^k)^2 = \frac{1}{4^{2n}} (C_{2n}^n)^2 \simeq \frac{1}{\pi n},$$

由于 $\sum \frac{1}{n} = \infty$, 平面上的对称的随机游动也是常返的.

我们再讨论空间中的对称随机游动. 这时质点的位置是空间中的整数格点, 每个位置有六个相邻的位置. 质点各以 $\frac{1}{6}$ 的概率转移到六个相邻位置中的每一个. 同样的, 空间中的对称随机游动也是周期为 2 的不可约链.

质点经过 $2n$ 步返回原位置的概率 u_n , 可类似的计算:

$$\begin{aligned} u_n &= \frac{1}{6^{2n}} \sum_{j,k \geq 0, j+k \leq n} \frac{(2n)!}{[j!k!(n-j-k)!]^2} \\ &= \frac{1}{2^{2n}} C_{2n}^n \sum_{j,k \geq 0, j+k \leq n} \left[\frac{1}{3^n} \frac{(n)!}{j!k!(n-j-k)!} \right]^2 \\ &\leq \frac{1}{2^{2n}} \max_{j,k \geq 0, j+k \leq n} \left[\frac{1}{3^n} \frac{(n)!}{j!k!(n-j-k)!} \right]^2. \end{aligned}$$

这里利用了三项式定理:

$$\sum_{j,k \geq 0, j+k \leq n} \left[\frac{1}{3^n} \frac{(n)!}{j!k!(n-j-k)!} \right] = 1$$

三项分布的最大项在 j 与 k 最接近 $\frac{n}{3}$ 时达到. 仍由斯特林公式可知, 这最大项与 $\frac{1}{n}$ 同阶, 从而 u_n 的阶数不超过 $\frac{1}{n^{3/2}}$. 但是 $\sum_n \frac{1}{n^{3/2}} < \infty$, 因此与直线和平面上的对称随机游动不同, 空间中的对称随机游动是非常返的.

更一般的, $d \geq 3$ 维空间中的对称随机游动也是一个周期为 2 的不可约链. 此时, 质点经过 $2n$ 步返回原位置的概率 u_n 的阶数不超过 $\frac{1}{n^{d/2}}$. 但是 $\sum_n \frac{1}{n^{d/2}} < \infty$, 因此 $d \geq 3$ 维空间中的对称随机游动是非常返的. 然而到直观上很难找可以接受的理由, 解释为什么 $d \geq 3$ 维空间与一二维空间中的对称随机游动在常返性上会截然不同. 这个结果通常被称为波利亚 (Polya) 定理. \square

§ 3.4 状态空间的分解

前面已提到, 马氏链的状态空间可以分为若干不同的等价类. 本节将进一步讨论状态空间的分解问题.

定义 设 $C \subset S$, 称 C 为 (随机) 闭集, 如对任意 $i \in C$ 及 $j \notin C$, 都有 $p_{ij} = 0$. 闭集 C 称为不可约的, 若 C 的状态相通. \square

引理 3.4.1 C 是闭集的充要条件为: 对任意 $i \in C$ 及 $j \notin C, n \geq 1$, 都有 $p_{ij}^{(n)} = 0$.

证: 只需证必要性. 用归纳法证之. 设 C 为闭集, 则由定义, 当 $n = 1$ 时, 结论成立. 现设 $n = l$ 时对任意 $i \in C, j \notin C$ 有 $p_{ij}^{(l)} = 0$, 则

$$p_{ij}^{(l+1)} = \sum_{k \in C} p_{ik}^{(l)} p_{kj} + \sum_{k \notin C} p_{ik}^{(l)} p_{kj} = \sum_{k \in C} p_{ik}^{(l)} \cdot 0 + \sum_{k \notin C} 0 \cdot p_{kj} = 0.$$

于是引理 3.4.1 得证. \square

易知, i 为吸收态则等价于单点集 $\{i\}$ 是闭集. 显然整个状态空间 S 构成一闭集.

§ 3.3 中例 3(b) 的 $\{1, 2\}$ 及 $\{3, 4, 5\}$ 分别为闭集.

闭集 C 的直观意义是自 C 内部不能到达 C 的外部, 这意味着系统一旦进入闭集 C 内, 它就永远在 C 中运动.

定理 3.4.1 所有常返状态构成一闭集.

证: 设 i 为常返, 且 $i \rightarrow j$, 则由定理 3.3.7 知 $i \leftrightarrow j$, j 亦为常返. 说明从常返状态出发, 只能到达常返状态, 不可能到达非常返状态. 从而定理得证. \square

今后用 C 表示所有常返状态构成的闭集. T 表所有非常返状态组成的集合.

推论 不可约马氏链或者没有非常返状态或者没有常返状态. \square

定理 3.4.2 设 $C \neq \emptyset$, 则它可分为若干个相互不相交的闭集 $\{C_n\}$, 使 $C = C_1 \cup C_2 \cup \dots$, 且有

1° C_n 中任两状态相通;

2° $C_h \cap C_l = \emptyset, h \neq l$, 即 C_h 中任一状态与 C_l 中的任一状态互不相通, 即 $\{C_n\}$ 均为互不相通闭集.

证: 因 $C \neq \emptyset$, 任取 $i_1 \in C$, 令 $C_1 = \{i : i \leftrightarrow i_1 \in C\}$, 若 $C - C_1 \neq \emptyset$, 再任取 $i_2 \in C - C_1$, 令 $C_2 = \{i : i \leftrightarrow i_2 \in C - C_1\}, \dots$, 若 $C - \bigcup_{i=1}^h C_i \neq \emptyset$ 取 $i_{h+1} \in C - \bigcup_{i=1}^h C_i$, 令

$$C_{h+1} = \{i : i \leftrightarrow i_{h+1} \in C - \bigcup_{i=1}^h C_i\}, \dots$$

显然, 由 $\{C_h\}$ 的构成即得定理的结论. \square

推论 状态空间 S 可分解为

$$S = T \cup C = T \cup C_1 \cup C_2 \cup \dots \quad (3.4.1)$$

其中 $\{C_h\}$ 为基本常返闭集, T 不一定是闭集. \square

因此, 当系统从某非常返状态出发, 系统可能一直在非常返集 T 中 (当 T 为闭集时), 也可能在某时刻离开 T 进入到某一基本常返闭集 C_h 中运动.

若 S 为有限集, 则有以下结论:

定理 3.4.3 若 S 为有限集, 则 T 一定是非闭集, 亦即不管系统自什么状态出发, 迟早要进入常返闭集.

证: 因 $T \subset S$ 有限, 又根据定理 3.3.4, 系统至多有限次返回非常返态, 从而只有有限次返回 T . 换言之, 系统迟早将进入常返闭集. \square

推论 有限不可约马氏链的状态都是常返的, 即 $T = \emptyset, S = C$. \square

引理 3.4.2 设 $C_h \subset S$ 为闭集, 只考虑 C_h 上所得的 m 步转移子矩阵 $\mathbf{P}_h^{(m)} = (p_{ij}^{(m)}), i, j \in C_h$, 则它们为随机矩阵.

证: 任取 $i \in C_h$, 由引理 3.4.1, 有

$$1 = \sum_{j \in S} p_{ij}^{(m)} = \sum_{j \in C_h} p_{ij}^{(m)} + \sum_{j \notin C_h} p_{ij}^{(m)} = \sum_{j \in C_h} p_{ij}^{(m)}.$$

显然, $p_{ij}^{(m)} \geq 0, i, j \in C_h$. 故局限在 C_h 上的 $\mathbf{P}_h^{(m)} = (p_{ij}^{(m)})(i, j \in C_h)$ 为随机矩阵. \square

为了计算与分析的方便, 有时我们把状态空间中的状态顺序按如下规则重新排列:

(1) 属于同一等价类的状态接连不断地依次编号, (2) 安排不同等价类的先后次序, 使得系统从一给定状态可以达到同一类的另一状态或到达前面的等价类, 但不能到达后面的等价类. 由定理 3.4.2 知, 由常返状态组成的等价类是一闭集, 而由非常返状态组成的等价类不一定是闭集, 于是按上述规则, 常返状态的类放在非常返类之前.

设 $S = C \cup T, C = C_1 \cup C_2 \cup \cdots \cup C_h$ 及 $T = T_{h+1} \cup \cdots \cup T_n$, 这是按上面规则编排的等价类次序. 其中 C_1, C_2, \cdots, C_h 是常返等价类 (闭集), T_{h+1}, \cdots, T_n 是非常返等价类. 于是, 转移概率矩阵可分解成如下形式:

$$\mathbf{P} = \begin{bmatrix} \mathbf{P}_1 & \mathbf{0} & \cdots & \mathbf{0} & \mathbf{0} & \cdots & \mathbf{0} \\ \mathbf{0} & \mathbf{P}_2 & \cdots & \mathbf{0} & \mathbf{0} & \cdots & \mathbf{0} \\ \vdots & \vdots & \ddots & \vdots & \vdots & \cdots & \vdots \\ \mathbf{0} & \mathbf{0} & \cdots & \mathbf{P}_h & \mathbf{0} & \cdots & \mathbf{0} \\ \mathbf{R}_{h+1,1} & \mathbf{R}_{h+1,2} & \cdots & \mathbf{R}_{h+1,h} & \mathbf{Q}_{h+1} & \cdots & \mathbf{0} \\ \vdots & \vdots & \cdots & \vdots & \vdots & \ddots & \vdots \\ \mathbf{R}_{n,1} & \mathbf{R}_{n,2} & \cdots & \mathbf{R}_{n,h} & \mathbf{R}_{n,h+1} & \cdots & \mathbf{Q}_n \end{bmatrix} = \begin{bmatrix} \mathbf{P}_C & \mathbf{0} \\ \mathbf{R} & \mathbf{Q}_T \end{bmatrix} \quad (3.4.2)$$

这里

$$\mathbf{P}_C = \begin{bmatrix} \mathbf{P}_1 & \mathbf{0} & \cdots & \mathbf{0} \\ \mathbf{0} & \mathbf{P}_2 & \cdots & \mathbf{0} \\ \vdots & \vdots & \ddots & \vdots \\ \mathbf{0} & \mathbf{0} & \cdots & \mathbf{P}_h \end{bmatrix}, \quad \mathbf{Q}_T = \begin{bmatrix} \mathbf{Q}_{h+1} & \mathbf{0} & \cdots & \mathbf{0} \\ \mathbf{R}_{h+2,h+1} & \mathbf{Q}_{h+2} & \cdots & \mathbf{0} \\ \vdots & \vdots & \ddots & \vdots \\ \mathbf{R}_{n,h+1} & \mathbf{R}_{n,h+2} & \cdots & \mathbf{Q}_n \end{bmatrix},$$

3.5 P^n 的极限性态与平稳分布

$$R = \begin{bmatrix} R_{h+1,1} & R_{h+1,2} & \cdots & R_{h+1,h} \\ R_{h+2,1} & R_{h+2,2} & \cdots & R_{h+2,h} \\ \vdots & \vdots & \ddots & \vdots \\ R_{n,1} & R_{n,2} & \cdots & R_{n,h} \end{bmatrix}.$$

其中 $P_l (1 \leq l \leq h)$ 是局限在 C_l 上的转移概率矩阵; $Q_l (h+1 \leq l \leq n)$ 是局限在 T_l 上的转移概率矩阵.

以 § 3.3 例 3(c) 的转移概率矩阵为例, 它可重新排列分解如下:

$$P = \begin{bmatrix} 1 & 0 & 0 & 0 & 0 \\ 0 & 1 & 0 & 0 & 0 \\ 0.3 & 0 & 0.6 & 0.1 & 0 \\ 0.2 & 0 & 0.2 & 0.5 & 0.1 \\ 0.1 & 0.1 & 0.2 & 0.2 & 0.4 \end{bmatrix}$$

则对应的 P_C, Q_T, R 为

$$P_C = \begin{bmatrix} 1 & 0 \\ 0 & 1 \end{bmatrix}, \quad Q_T = \begin{bmatrix} 0.6 & 0.1 & 0 \\ 0.2 & 0.5 & 0.1 \\ 0.2 & 0.2 & 0.4 \end{bmatrix}, \quad R = \begin{bmatrix} 0.3 & 0 \\ 0.2 & 0 \\ 0.1 & 0.1 \end{bmatrix}.$$

我们还有以下简单而有效的定理.

定理 3.4.4 若转移概率矩阵按 (3.4.2) 式的形式分解, 则

1° $P_l (1 \leq l \leq h)$ 是局限在 C_l 上的随机矩阵;

2°

$$P^n = \begin{bmatrix} P_C^n & \mathbf{0} \\ R_n & Q_T^n \end{bmatrix}. \quad (3.4.3)$$

其中 $R_1 = R, R_n = R_{n-1}P_C + Q_T^{n-1}R$.

3° $\lim_{n \rightarrow \infty} Q_T^n = \mathbf{0}$. 其中 $\mathbf{0}$ 表零矩阵.

证: 1° 由定理 3.4.2 及引理 3.4.2 即得;

2° 由归纳可证之;

3° 由定理 3.3.2 推论 1 的 (3.3.13) 式即得. □

§ 3.5 P^n 的极限性态与平稳分布

89

在实际应用中, 人们常常关心的问题有两个: (a) 当 $n \rightarrow \infty$ 时, $P(X_n = i) = \pi_i(n)$ 的极限是否存在? (b) 在什么条件下, 一个马氏链是一个平稳序列? 对于前者, 由于

$\pi_j(n) = \sum_{i \in S} \pi_i(0) p_{ij}^{(n)}$ 故可转化为研究 $p_{ij}^{(n)}$ 的渐近性质, 即 $\lim_{n \rightarrow \infty} p_{ij}^{(n)}$ 是否存在? 若存在, 其极限是否与 i 有关? 对于后者, 实际上是一个平稳分布是否存在的问题. 这两个问题有密切联系.

1. P^n 的极限性态

$p_{ij}^{(n)}$ 的渐近性态, 在 § 3.3 中已有所涉及, 这里分两种情形再加以进一步讨论.

(1). j 非常返或零常返

定理 3.5.1 若 j 非常返或零常返, 则对任意 $i \in S$, 有

$$\lim_{n \rightarrow \infty} p_{ij}^{(n)} = 0. \quad (3.5.1)$$

证: 当 j 为非常返时, 上述结论已在 § 3.3 定理 3.3.2 的推论 1 中证过. 故只需证 j 为零常返的情形. 取 $m < n$, 有

$$p_{ij}^{(n)} = \sum_{l=1}^n f_{ij}^{(l)} p_{jj}^{(n-l)} \leq \sum_{l=1}^m f_{ij}^{(l)} p_{jj}^{(n-l)} + \sum_{l=m+1}^n f_{ij}^{(l)}. \quad (3.5.2)$$

固定 m 先令 $n \rightarrow \infty$, 由 § 3.3 定理 3.3.6 知, 上式右方第一项趋于 0 (因为 $p_{jj}^{(n)} \rightarrow 0$, 且是有限项的和); 再令 $m \rightarrow \infty$, 第二项因 $\sum_{l=1}^{\infty} f_{ij}^{(l)} \leq 1$ 而趋于 0. 故 $p_{ij}^{(n)} \rightarrow 0 (n \rightarrow \infty)$. \square

推论 1 有限马氏链没有零常返状态.

证: 设有某状态 i 是零常返, 令 $C_i = \{j : i \leftrightarrow j\}$, 由 § 3.3 定理 3.4.2 知 C_i 是相通的常返闭集, 且 $C_i \in S$ 为有限集. 由定理 3.4.4 有 $\sum_{j \in C_i} p_{ij}^{(n)} = 1 (n \geq 1)$. 但由定理 3.5.1 知 $\lim_{n \rightarrow \infty} \sum_{j \in C_i} p_{ij}^{(n)} = 0$, 二者矛盾. 故 S 有有限时无零常返状态. \square

推论 2 不可约的有限马氏链的状态都是正常返的.

证: 由推论 1 及定理 3.4.3 的推论即得. \square

推论 3 若马氏链有一零常返态, 则必有无限多个零常返状态.

证: 由推论 1 即得. \square

(2). j 为正常返态

这时情况较复杂, $\lim_{n \rightarrow \infty} p_{ij}^{(n)}$ 不一定存在, 即使存在也可能与 i 有关. 但有以下结论:

定理 3.5.2 若 j 正常返, 周期为 d , 则对任意 $i \in S$ 及 $0 \leq r \leq d-1$, 有

$$\lim_{n \rightarrow \infty} p_{ij}^{(nd+r)} = f_{ij} \cdot \frac{d}{\mu_j} \quad (3.5.3)$$

其中 $f_{ij}(r) = \sum_{m=0}^{\infty} f_{ij}^{(md+r)}$, $0 \leq r \leq d-1$. \square

3.5 P^n 的极限性态与平稳分布

此定理的证明可见参考书 [5].

推论 1 若 j 是遍历状态, 则对任意的 $i \in S$, 有

$$\lim_{n \rightarrow \infty} p_{ij}^{(n)} = \frac{f_{ij}}{\mu_j}. \quad \square \quad (3.5.4)$$

推论 2 对于不可约的遍历链 (即所有状态遍历), 对任意 $i, j \in S$, 有

$$\lim_{n \rightarrow \infty} p_{ij}^{(n)} = \frac{1}{\mu_j}. \quad \square \quad (3.5.5)$$

定理 3.5.3 若 j 常返, 则对任意 $i \in S$, 有

$$\lim_{n \rightarrow \infty} \frac{1}{n} \sum_{l=1}^n p_{ij}^{(l)} = \frac{f_{ij}}{\mu_j}. \quad \square \quad (3.5.6)$$

证明参见 [6] 或 [7].

推论 如不可约马氏链的状态是常返状态, 则对任意 $i, j \in S$, 有

$$\lim_{n \rightarrow \infty} \frac{1}{n} \sum_{l=1}^n p_{ij}^{(l)} = \frac{1}{\mu_j}. \quad \square \quad (3.5.7)$$

该推论直观解释如下: $\sum_{l=1}^n p_{ij}^{(l)}$ 表示自 i 出发在前 n 个单位时间内到达 j 的总次数, 故 $\frac{1}{n} \sum_{l=1}^n p_{ij}^{(l)}$ 表示每单位时间到达 j 的平均次数, 而 $\frac{1}{\mu_j}$ 亦表示每单位时间到达 j 的平均次数. 故对不可约常返链, 有: $\frac{1}{n} \sum_{l=1}^n p_{ij}^{(l)} \rightarrow \frac{1}{\mu_j}$.

定理 3.5.4 若马氏链是不可约的遍历链, 则 $\{\pi_i = \frac{1}{\mu_i}\}$ 是方程组

$$x_j = \sum_{i \in S} x_i p_{ij} \quad (3.5.8)$$

满足条件 $x_j \geq 0, j \in S, \sum_{j \in S} x_j = 1$ 的唯一解.

证: 记 $\pi_i = \frac{1}{\mu_i}$, 由定理 3.5.2 推论 2 有

$$\lim_{n \rightarrow \infty} p_{ij}^{(n)} = \frac{1}{\mu_j} = \pi_j.$$

对任意 n, M , 有

$$1 = \sum_{j \in S} p_{ij}^{(n)} \geq \sum_{j=1}^M p_{ij}^{(n)},$$

固定 M , 令 $n \rightarrow \infty$, 可得 $\sum_{j=1}^M \pi_j \leq 1$; 再令 $M \rightarrow \infty$, 知

$$\sum_{j \in S} \pi_j \leq 1.$$

由 C-K 方程有

$$91 \quad p_{ij}^{(n+1)} \geq \sum_{l=1}^M p_{il}^{(n)} p_{lj}.$$

如令 $n \rightarrow \infty$, 则得 $\pi_j \geq \sum_{l=1}^M \pi_l p_{lj}$ 再令 $M \rightarrow \infty$, 有

$$\pi_j \geq \sum_{l \in S} \pi_l p_{lj}, \quad \forall j \in S. \quad (3.5.9)$$

将 (3.5.9) 式两边乘以 p_{ji} 并对 j 求和, 得

$$\pi_i \geq \sum_{j \in S} \pi_j p_{ji} \geq \sum_{l \in S} \pi_l p_{li}^{(2)}.$$

重复上述步骤, 得 $\pi_j \geq \sum_{i \in S} \pi_i p_{ij}^{(n)}$ 对所有 $j \in S$ 及 $n \geq 1$ 成立. 现设上式对某个 j 严格不等式成立, 即 $\pi_j > \sum_{i \in S} \pi_i p_{ij}^{(n)}$, 那么, 将此式对 j 求和, 有

$$\sum_{j \in S} \pi_j > \sum_{j \in S} \sum_{i \in S} \pi_i p_{ij}^{(n)} = \sum_{i \in S} \pi_i \sum_{j \in S} p_{ij}^{(n)} = \sum_{i \in S} \pi_i,$$

但这是不可能的. 于是对所有 n 及 j , 有

$$\pi_j = \sum_{i \in S} \pi_i p_{ij}^{(n)}. \quad (3.5.10)$$

由于 $\sum_{j \in S} \pi_i \leq 1$, 且 $p_{ij}^{(n)}$ 关于 n 一致有界, 故在 (3.5.10) 式中令 $n \rightarrow \infty$ 时, 由控制收敛定理, 有

$$\pi_j = \lim_{n \rightarrow \infty} \sum_{i \in S} \pi_i p_{ij}^{(n)} = \sum_{i \in S} \pi_i \cdot \lim_{n \rightarrow \infty} p_{ij}^{(n)} = \left(\sum_{i \in S} \pi_i \right) \cdot \pi_j.$$

由于 $\pi_j > 0$, 故得

$$\sum_{i \in S} \pi_i = 1.$$

现证唯一性. 设 $\{v_i\}$ 是满足条件的另一组解, 则类似 (3.5.10) 有

$$v_j = \sum_{i \in S} v_i p_{ij} = \cdots = \sum_{i \in S} v_i p_{ij}^{(n)}.$$

令 $n \rightarrow \infty$ 则有

$$v_j = \sum_{i \in S} v_i \lim_{n \rightarrow \infty} p_{ij}^{(n)} = \pi_j \cdot \left(\sum_{i \in S} v_i \right) = \pi_j. \quad \square$$

2. 平稳分布

定义 一个定义在 S 上的概率分布 $\pi = \{\pi_1, \pi_2, \dots, \pi_i, \dots\}$ 称为 **马氏链的平稳分布**. 如有

$$\pi = \pi \mathbf{P}. \quad (3.5.11)$$

3.5 \mathbf{P}^n 的极限性态与平稳分布

即 $\forall j \in S$,

$$\pi_j = \sum_{i \in S} \pi_i p_{ij}. \quad \square \quad (3.5.12)$$

平稳分布也称马氏链的不变概率测度. 对于一个平稳分布 π , 显然有

$$\pi = \pi \mathbf{P} = \pi \mathbf{P}^2 = \cdots = \pi \mathbf{P}^n. \quad (3.5.13)$$

定理 3.5.5 设 $\{X_n, n \geq 0\}$ 是马氏链, 则 $\{X_n, n \geq 0\}$ 为平稳过程的充要条件是 $\pi(0) = (\pi_i(0), i \in S)$ 是平稳分布, 即

$$\pi(0) = \pi(0)\mathbf{P}.$$

证: 充分性. 记 $\pi(0) = \pi$, 显然

$$\pi(1) = \pi(0)\mathbf{P} = \pi\mathbf{P} = \pi, \quad \cdots \quad \pi(n) = \pi(n-1)\mathbf{P} = \pi\mathbf{P} = \pi.$$

因此 $\forall i_k \in S, t_k \in \mathbb{N}, n \geq 1, 1 \leq k \leq n, t \in \mathbb{N}$ 有

$$\begin{aligned} P(X_{t_1} = i_1, X_{t_2} = i_2, \cdots, X_{t_n} = i_n) &= \pi_{i_1}(t_1) p_{i_1 i_2}^{(t_2 - t_1)} \cdots p_{i_{n-1} i_n}^{(t_n - t_{n-1})} \\ &= \pi_{i_1}(t_1 + t) p_{i_1 i_2}^{(t_2 - t_1)} \cdots p_{i_{n-1} i_n}^{(t_n - t_{n-1})} \\ &= P(X_{t_1+t} = i_1, X_{t_2+t} = i_2, \cdots, X_{t_n+t} = i_n). \end{aligned}$$

所以 $\{X_n, n \geq 0\}$ 是严平稳过程.

必要性. 由于 $\{X_n, n \geq 0\}$ 是平稳过程, 因此有 $\pi(n) = \pi(n-1) = \cdots = \pi(0)$. 又由 $\pi(1) = \pi(0)\mathbf{P}$ 得 $\pi(0) = \pi(0)\mathbf{P}$. 即 $\pi(0)$ 是平稳分布. \square

由定理 3.5.4 有以下结论:

定理 3.5.6 不可约遍历链恒有唯一的平稳分布 $\{\pi_i = \frac{1}{\mu_i}\}$, 且 $\pi_j = \lim_{n \rightarrow \infty} p_{ij}^{(n)}$. \square

对于一般的马氏链, 其平稳分布是否存在? 若存在, 是否唯一? 有以下的定理.

定理 3.5.7 令 C_+ 为马氏链中全体正常返状态构成的集合. 则有:

- (a) 平稳分布不存在的充要条件为 $C_+ = \emptyset$;
- (b) 平稳分布唯一存在的充要条件为只有一个基本正常返闭集 $C_a = C_+$;
- (c) 有限状态马氏链的平稳分布总存在;
- (d) 有限不可约非周期马氏链存在唯一的平稳分布.

证: (a) 充分性. 用反证法, 假设该马氏链存在一个平稳分布 $\pi \neq 0$, 则由平稳分布定义知有 $\pi = \pi \mathbf{P}$, 则 $\forall n \geq 1, \pi = \pi \mathbf{P} = \cdots = \pi \mathbf{P}^n$, 让 $n \rightarrow \infty$. 因 $C_+ = \emptyset$, 故该马氏链中均是零常返态或非常返态, 而由定理 3.5.1 知 $\mathbf{P}^n \rightarrow \mathbf{0}$, 当 $n \rightarrow \infty$ 时, 与 $\pi \neq 0$ 矛盾. 所以该马氏链不存在平稳分布.

93

必要性. 仍用反证法, 假设 $C_+ \neq \emptyset$, 不妨设 $C_+ = C$ 只有一个正常返的闭集, 则类似于定理 3.5.4 可以证明该马氏链限制在 C 上存在一平稳分布 π_1 使 $\pi_1 = \pi_1 \mathbf{P}_1$, 其中 \mathbf{P}_1

是一步转移概率矩阵 \mathbf{P} 在 C 上的限制. 即 $\mathbf{P} = \begin{pmatrix} \mathbf{P}_1 & \mathbf{0} \\ \mathbf{R} & \mathbf{Q}_T \end{pmatrix}$. 此时只需取 $\pi = (\pi_1, \mathbf{0})$,

则有 $\pi \mathbf{P} = (\pi_1, \mathbf{0}) \begin{pmatrix} \mathbf{P}_1 & \mathbf{0} \\ \mathbf{R} & \mathbf{Q}_T \end{pmatrix} = (\pi_1 \mathbf{P}_1, \mathbf{0}) = (\pi_1, \mathbf{0}) = \pi$. 可见, π 是平稳分布, 与平稳分布不存在矛盾. 故 $C_+ = \emptyset$.

(b) 充分性. 因该马氏链只有一个基本正常返闭集, 故类似于定理 3.5.4 可证明该马氏链存在唯一的平稳分布.

必要性. 首先, 因它存在一个平稳分布, 故由 (a) 知 $C_+ \neq \emptyset$. 又不妨假设其常返状态集可分解为两个常返闭集的并, 即 $C_+ = C_a \cup C_b$. 则易知一步转移概率矩阵 \mathbf{P} 可写为

$$\mathbf{P} = \begin{pmatrix} \mathbf{P}_1 & \mathbf{0} & \mathbf{0} \\ \mathbf{0} & \mathbf{P}_2 & \mathbf{0} \\ \mathbf{R}_1 & \mathbf{R}_2 & \mathbf{Q}_T \end{pmatrix}. \text{ 其中 } \mathbf{P}_1, \mathbf{P}_2 \text{ 分别是 } \mathbf{P} \text{ 在 } C_a, C_b \text{ 上的限制. 类似于定理 3.5.4 可}$$

证明存在 π_1, π_2 使得 $\pi_1 = \pi_1 \mathbf{P}_1$, 且 $\pi_2 = \pi_2 \mathbf{P}_2$, 若取 $\pi = (\pi_1, \mathbf{0}, \mathbf{0})$, $\pi' = (\mathbf{0}, \pi_2, \mathbf{0})$, 则易知 $\pi \mathbf{P} = (\pi_1 \mathbf{P}_1, \mathbf{0}, \mathbf{0}) = (\pi_1, \mathbf{0}, \mathbf{0}) = \pi$, $\pi' \mathbf{P} = (\mathbf{0}, \pi_2, \mathbf{0}) = \pi'$. 可见 π 与 π' 均是平稳分布, 与唯一性矛盾. 故该马氏链只有一个基本正常返闭集 $C_a = C_+$.

(c) 由定理 3.4.3 及定理 3.5.1 的推论 1 可知, 有限状态马氏链总存在正常返状态, 即对有限状态马氏链总有 $C_+ \neq \emptyset$, 故由 (a) 知它的平稳分布总存在.

(d) 由定理 3.5.1 的推论 2 及定理 3.5.6 易得. \square

3. $\lim_{n \rightarrow \infty} \pi_j(n)$ 的存在性

下面我们来研究 $\lim_{n \rightarrow \infty} \pi_j(n)$ 的存在性问题.

定义 若 $\lim_{n \rightarrow \infty} \pi_j(n) = \pi_j^* (j \in S)$ 存在, 则称 $\pi^* = \{\pi_1^*, \dots, \pi_j^*, \dots\}$ 为马氏链的极限分布.

定理 3.5.8 非周期不可约链是正常返的充要条件是它存在平稳分布, 且此时平稳分布就是极限分布.

证: 充分性. 设存在平稳分布 $\pi = \{\pi_1, \dots, \pi_j, \dots\}$, 由此有 $\pi = \pi \mathbf{P} = \pi \mathbf{P}^n = \dots = \pi \mathbf{P}^n$, 即 $\pi_j = \sum_{i \in S} \pi_i p_{ij}^{(n)}$. 由于 $\pi_i \geq 0$, $\sum_{j \in S} \pi_j = 1$, 当 $n \rightarrow \infty$, 利用控制收敛定理, 极限号与和式可交换, 得

$$\pi_j = \lim_{n \rightarrow \infty} \sum_{i \in S} \pi_i p_{ij}^{(n)} = \sum_{i \in S} \pi_i \left(\lim_{n \rightarrow \infty} p_{ij}^{(n)} \right) = \left(\sum_{i \in S} \pi_i \right) \cdot \frac{1}{\mu_j} = \frac{1}{\mu_j}.$$

因为 $\sum_{j \in S} \pi_j = \sum_{j \in S} \frac{1}{\mu_j} = 1$. 于是至少存在一个 $\pi_l = \frac{1}{\mu_l} > 0$, 从而

$$\lim_{n \rightarrow \infty} p_{il}^{(n)} = \frac{1}{\mu_l} \neq 0,$$

即 $\mu_l < \infty$ 故 l 为正常返状态. 由不可约性知, 整个链是正常返的, 且所有 $\pi_j = \frac{1}{\mu_j} > 0$.

3.5 \mathbf{P}^n 的极限性态与平稳分布

必要性. 由于马氏链是正常返非周期链, 即为遍历链, 由定理 3.5.6 立即得证. 且所有 $\pi_j = \pi_j^* = \frac{1}{\mu_j}$, $j \in S$. \square

由上可知, 对于不可约遍历链, 则极限分布 $\pi^* = \pi$ 存在且等于平稳分布. 这意味着当 n 充分大时,

$$P(X_n = j) \approx \pi_j = \frac{1}{\mu_j},$$

即 $\{X_n, n \geq 0\}$ 是一渐近平稳序列. 这在实际问题中是很有意义的.

例 1 设

$$S = \{1, 2\}, \quad \mathbf{P} = \begin{bmatrix} \frac{3}{4} & \frac{1}{4} \\ \frac{5}{8} & \frac{3}{8} \end{bmatrix},$$

求平稳分布及 $\lim_{n \rightarrow \infty} \mathbf{P}^n = ?$

解: 由 $\pi = \pi \mathbf{P}$ 得 $\pi_1 = \frac{3}{4}\pi_1 + \frac{5}{8}\pi_2$ 及 $\pi_1 + \pi_2 = 1$, 解得 $\pi_1 = \frac{5}{7}, \pi_2 = \frac{2}{7}$, 故

$$\pi = \left(\frac{5}{7}, \frac{2}{7} \right).$$

由 $\lim_{n \rightarrow \infty} p_{ij}^{(n)} = \pi_j = \frac{1}{\mu_j}$, 故

$$\mu_1 = \frac{7}{5}, \quad \mu_2 = \frac{7}{2}.$$

且

$$\lim_{n \rightarrow \infty} \mathbf{P}^n = \lim_{n \rightarrow \infty} \begin{bmatrix} \frac{3}{4} & \frac{1}{4} \\ \frac{5}{8} & \frac{3}{8} \end{bmatrix}^n = \begin{bmatrix} \frac{5}{7} & \frac{2}{7} \\ \frac{5}{7} & \frac{2}{7} \end{bmatrix}. \quad \square$$

例 2 设 $\{X_n, n \geq 0\}$ 为艾伦费斯特链. $S = \{0, 1, 2, \dots, 2N\}$, 转移概率为

$$\begin{aligned} p_{ii} &= 0 \quad (0 \leq i \leq 2N), \\ p_{i,i+1} &= \frac{2N-i}{2N} \quad (0 \leq i \leq 2N-1), \\ p_{i,i-1} &= \frac{i}{2N} \quad (1 \leq i \leq 2N). \end{aligned}$$

求此链的 π_j 及 μ_j ($i \in S$).

解: 由 $\pi = \pi \mathbf{P}$, 得

$$\begin{aligned} \pi_0 &= \frac{\pi_1}{2N}, \\ \pi_i &= \frac{2N-i+1}{2N} \pi_{i-1} + \frac{i+1}{2N} \pi_{i+1}, \quad 1 \leq i \leq 2N-1, \\ \pi_{2N} &= \frac{\pi_{2N-1}}{2N}. \end{aligned}$$

95

解此方程组得

$$\pi_i = C_{2N}^i \cdot \pi_0, \quad 1 \leq i \leq 2N.$$

又因为 $\sum_{i=0}^{2N} \pi_i = 1$ 因此 $\pi_0 = 2^{-2N}$, 于是有

$$\pi_i = C_{2N}^i 2^{-2N}, \quad 1 \leq i \leq 2N.$$

再由 $\mu_i = \frac{1}{\pi_i}$ 得

$$\mu_i = 2^{2N} \frac{i!(2N-i)!}{(2N)!}, \quad 0 \leq i \leq 2N. \quad \square$$

4. 求和 (积分) 与极限交换的原则

下面罗列几个关于求和 (积分) 与极限交换的重要定理, 这些定理可以看成是实变函数理论中有关定理的推广.

定理 3.5.9 (Levy 单调收敛定理) 设 $\pi = (\pi_i, i \in S)$ 是行向量, $\pi_i \geq 0, \forall i \in S$, 若列向量序列 $\{\mathbf{f}^{(n)}\}$, $\mathbf{f}^{(n)} = (f_1^{(n)}, f_2^{(n)}, \dots, f_i^{(n)}, \dots)^T$, 满足 $0 \leq \mathbf{f}^{(1)} \leq \dots \leq \mathbf{f}^{(n)} \leq \mathbf{f}^{(n+1)} \leq \dots$ 且 $\lim_{n \rightarrow \infty} \mathbf{f}^{(n)} = \mathbf{f}$. 则

$$\pi \mathbf{f} = \lim_{n \rightarrow \infty} \pi \mathbf{f}^{(n)},$$

即

$$\sum_{i \in S} \pi_i \left(\lim_{n \rightarrow \infty} f_i^{(n)} \right) = \lim_{n \rightarrow \infty} \sum_{i \in S} \pi_i f_i^{(n)}. \quad \square$$

定理 3.5.10 (Fatou 定理) 设 $\pi = (\pi_i, i \in S)$ 是行向量, $\pi_i \geq 0, \forall i \in S$, 若列向量序列 $\{\mathbf{f}^{(n)}\}$, $\mathbf{f}^{(n)} = (f_1^{(n)}, f_2^{(n)}, \dots, f_i^{(n)}, \dots)^T$, 满足 $\pi (\liminf_{n \rightarrow \infty} \mathbf{f}^{(n)}) \leq \liminf_{n \rightarrow \infty} \pi \mathbf{f}^{(n)}$ 且 $\lim_{n \rightarrow \infty} \mathbf{f}^{(n)} \triangleq \mathbf{f}$ 存在. 则

$$\pi \mathbf{f} \leq \liminf_{n \rightarrow \infty} \pi \mathbf{f}^{(n)}. \quad \square$$

定理 3.5.11 (Lebesgue 控制收敛定理) 设 $\pi = (\pi_i, i \in S)$ 是行向量, $\pi_i \geq 0, \forall i \in S$, 若列向量序列 $\{\mathbf{f}^{(n)}\}$, $\mathbf{f}^{(n)} = (f_1^{(n)}, f_2^{(n)}, \dots, f_i^{(n)}, \dots)^T$, 满足 $\mathbf{f}^{(n)} \geq 0$, $|\mathbf{f}^{(n)}| = (|f_1^{(n)}|, |f_2^{(n)}|, \dots, |f_i^{(n)}|, \dots)^T \leq c\mathbf{e}$, $\mathbf{e} = (1, 1, \dots)^T$, $c > 0$ 为常数, 且 $\lim_{n \rightarrow \infty} \mathbf{f}^{(n)} = \mathbf{f}$ 存在. 则

$$\pi \mathbf{f} = \lim_{n \rightarrow \infty} \pi \mathbf{f}^{(n)}. \quad \square$$

§ 3.6 离散时间的 Phase-Type 分布及其反问题

本节讨论离散时间的 Phase-Type 分布及其反问题, 先给出它的定义.

定义 设 $\{X_n, n \geq 0\}$ 是 M.C., 状态空间 $\tilde{S} = S \cup S_0$, $S = \{1, 2, \dots, p\}$ 为瞬态集, $S_0 = 0$ 为吸收态. 一步转移概率矩阵 $\tilde{\mathbf{P}} = \begin{bmatrix} \mathbf{P} & \mathbf{P}_0 \\ 0 & 1 \end{bmatrix}$, 其中, \mathbf{P} 为瞬态集的转移矩

3.6 离散时间的 Phase-Type 分布

阵, $\mathbf{P}_0 = (\mathbf{I} - \mathbf{P})e$, $e = (1, 1, \dots, 1)^T$ 为 p 为单位列向量, $\tau = \inf\{n : n \geq 0, X_n \in S_0\}$, 称 τ 为从瞬时态集到吸收态集的首达时间, 称 τ 的分布为 Phase-Type 分布 (简称 PH 分布).

令 $\pi(0) = (\alpha_0, \alpha)$, 其中 $\alpha = (\alpha_1, \dots, \alpha_p)$, $\alpha_k \geq 0$, $\sum_{k \in S} \alpha_k = 1$. $g_k = P(\tau = k)$, $g_k(i) = P(\tau = k | X_0 = i)$, $\mathbf{g}_k = (g_k(i), i \in S)^T$, $g(i, \lambda) = E(\lambda^\tau | X_0 = i)$, $\mathbf{g}(\lambda) = (g(i, \lambda), i \in S)$, $g(\lambda) = E(\lambda^\tau) = \sum_{k=0}^{\infty} g_k \lambda^k$.

下面先求 τ 的分布 $\{g_k, k \geq 1\}$, τ 的条件分布向量 $\{\mathbf{g}_k, k \geq 1\}$, 及其生成函数. 有如下的定理:

定理 3.6.1 在上述记号下, 有

1°

$$g_0 = \alpha_0, \forall k \geq 1$$

$$g_k = \alpha \mathbf{P}^{k-1} \mathbf{P}_0 = \alpha \mathbf{P}^{k-1} (\mathbf{I} - \mathbf{P})e; \quad (3.6.1)$$

2° $\mathbf{g}_0 = e$, $\forall k \geq 1$, 有

$$\mathbf{g}_k = \mathbf{P}^{k-1} \mathbf{P}_0 = \alpha \mathbf{P}^{k-1} (\mathbf{I} - \mathbf{P})e; \quad (3.6.2)$$

3° $\forall 0 \leq \lambda \leq 1$, 有:

$$g(\lambda) = \alpha_0 + \lambda \alpha (\mathbf{I} - \lambda \mathbf{P})^{-1} (\mathbf{I} - \mathbf{P})e. \quad (3.6.3)$$

$$\mathbf{g}(\lambda) = \lambda (\mathbf{I} - \lambda \mathbf{P})^{-1} (\mathbf{I} - \mathbf{P})e. \quad (3.6.4)$$

证明 1° 用数学归纳法.

$$k=0 \text{ 时, } g_0 = P(\tau = 0) = P(X_0 \in S_0) = \alpha_0,$$

$$k=1 \text{ 时, } g_1 = P(\tau = 1) = P(X_0 \in S, X_1 = 0) = \sum_{i \in S} \alpha_i p_{i0} = \alpha \cdot \mathbf{P}_0,$$

$$\begin{aligned} k=2 \text{ 时, } g_2 &= P(\tau = 2) = P(X_0 \in S, X_1 \in S, X_2 \in S_0) \\ &= \sum_{i \in S} \sum_{j \in S} P(X_0 = i, X_1 = j, X_2 = 0) = \sum_{i \in S} \sum_{j \in S} \alpha_i p_{ij} p_{j0} = \alpha \cdot \mathbf{P}^{2-1} \cdot \mathbf{P}_0, \end{aligned}$$

假设 $k = n$ 时命题成立, 即: $g_n = \alpha \mathbf{P}^{n-1} \mathbf{P}_0 = \alpha \mathbf{P}^{n-1} (\mathbf{I} - \mathbf{P})e$, 则当 $k = n+1$ 时, 可以仿照上面作如下的事件分解: 1) 从初始状态 i 转移一步到 j , 2) 以 j 作为初始状态然后转移 n 步被吸收, 则结合归纳假设有

$$g_{n+1} = P(\tau = n+1) = \alpha \mathbf{P} \mathbf{P}^{n-1} \mathbf{P}_0 \stackrel{2.7}{=} \alpha \mathbf{P}^n \mathbf{P}_0 = \alpha \mathbf{P}^{(n+1)-1} \mathbf{P}_0 = \alpha \mathbf{P}^n (\mathbf{I} - \mathbf{P})e$$

知当 $k = n+1$ 时, 命题成立。

綜上有: $\forall k \in N$, $g_0 = \alpha_0$, $g_k = \alpha \mathbf{P}^{k-1} \mathbf{P}_0 = \alpha \mathbf{P}^{k-1} (\mathbf{I} - \mathbf{P}) e$ 。

2° 类似于 1° 的证明, 即得 (3.6.2) 式,

3° 为了证明 3° 我们先给出一个引理:

引理 设矩阵 \mathbf{Q} 满足 $\lim_{n \rightarrow \infty} \mathbf{Q}^n = 0$, 则 $(\mathbf{I} - \mathbf{Q})^{-1}$ 存在, 且

$$(\mathbf{I} - \mathbf{Q})^{-1} = \sum_{k=1}^{\infty} \mathbf{Q}^k \quad (3.6.4)$$

其中 \mathbf{I} 为单位矩阵。

证: 因

$$(\mathbf{I} - \mathbf{Q}) \cdot (\mathbf{I} + \mathbf{Q} + \mathbf{Q}^2 + \cdots + \mathbf{Q}^{n-1}) = \mathbf{I} - \mathbf{Q}^n. \quad (3.6.5)$$

由已知有: $\lim_{n \rightarrow \infty} \mathbf{Q}^n = 0$, 故行列式 $|\mathbf{I} - \mathbf{Q}^n| \rightarrow 1$, ($n \rightarrow \infty$), 所以, 当 n 充分大时, $|\mathbf{I} - \mathbf{Q}^n| \neq 0$, 从而

$$|\mathbf{I} - \mathbf{Q}| \cdot |\mathbf{I} + \mathbf{Q} + \mathbf{Q}^2 + \cdots + \mathbf{Q}^{n-1}| \neq 0.$$

这当上式左边两个行列式均不为 0 时才成立. 于是: $|\mathbf{I} - \mathbf{Q}| \neq 0$, 即 $(\mathbf{I} - \mathbf{Q})^{-1}$ 存在. 以 $(\mathbf{I} - \mathbf{Q})^{-1}$ 左乘 (3.6.5) 式两边, 并令 $n \rightarrow \infty$ 则得 (3.6.4) 式. \square

以下证明 3°:

将 g_k 与 \mathbf{g}_k 的表达式分别代入 $g(\lambda) = \sum_{k=0}^{\infty} g_k \lambda^k$ 及 $\mathbf{g}(\lambda) = \sum_{k=0}^{\infty} \mathbf{g}_k \lambda^k$ 中, 并注意到 S 为瞬时态集, 故 $\lim_{n \rightarrow \infty} \mathbf{P}^n = 0$, 用引理即可得 3°。

在理论与实际应用中, 常常感兴趣的问题是所谓 PH -分布的反问题, 即已知以上马氏链的首达时间的条件分布向量序列 $\{\mathbf{g}_k, k \geq 1\}$, 能否求其 \mathbf{P} 与 \mathbf{P}_0 ? 下面给出肯定的回答:

记 $B(k, p) = (\mathbf{g}_k, \mathbf{g}_{k+1}, \cdots, \mathbf{g}_{k+p-1})$ 为 $p \times p$ 矩阵, 称为该马氏链首达时间 τ 的条件分布向量矩阵. 有以下的:

定理 3.6.2 在上述记号下, 有

1° $\forall k \geq 1$, 有

$$\mathbf{g}_k = \mathbf{P} \mathbf{g}_{k-1}; \quad (3.6.5)$$

$$B(k, p) = \mathbf{P} \cdot B(k-1, p); \quad (3.6.6)$$

2° 若 $\text{rank} B(0, p) = p$, 则

$$\mathbf{P} = B(1, p) B^{-1}(0, p); \quad (3.6.7)$$

$$\mathbf{P}_0 = (\mathbf{I} - B(1, p) B^{-1}(0, p)) e; \quad (3.6.8)$$

3° 若 $\text{rank} B(0, p) = p$, 则

98

$$\mathbf{g}_k = B(1, p) B^{-1}(0, p) \mathbf{g}_{k-1}. \quad (3.6.9)$$

3.7 首达目标模型与其它模型的关系

证明: 1° 由 3.6.2 即得 3.6.5 及 3.6.6 ;

2° 当 $\text{rank} B(0, p) = p$ 时, 由 3.6.6 即得 3.6.7 及 3.6.8 。

3° 由 2° 即得。

上述定理说明: 若 $\text{rank} B(0, p) = p$, 则 \mathbf{P}, \mathbf{P}_0 可由 $B(1, p)$ 唯一确定, 且首达时间 τ 的条件分布向量序列由 $B(1, p)$ 唯一确定。

问题 1, 当 $\text{rank} B(0, p) = r$, 而 $1 \leq r < p$ 时, 请有兴趣的读者作为练习研究并给出其答案。

在物理与工程技术管理中往往有这种问题, 即某系统的内部参数未知 (例如 \mathbf{P}, \mathbf{P}_0 未知), 但其对外的某些指标是可以观察到的 (例如 τ 的观测值)。如何由能观测到的外部参数估计其内部参数? 这是有意义的理论与应用问题。

问题 2, 如何用 $B(k, p)$ 来表示 $g(\lambda)$? 请有兴趣的读者给出答案。

PH 分布有如下的一些性质:

性质 3.6.1 若 τ_1, τ_2 为 PH 分布, 则 $\tau_1 + \tau_2, \tau_1 \wedge \tau_2, \tau_1 \vee \tau_2$ 均为 PH 分布。

性质 3.6.2 τ_1, \dots, τ_n 为 PH 分布, ξ 为 $d.r.v.$, 与 τ_1, \dots, τ_n 独立, 且 $P(\xi = k) = p_k, 1 \leq k \leq n$ 。则: $\sum_{k=1}^n \tau_k I_{(\xi=k)}$ 为 PH 分布。

性质 3.6.3 设 τ 为 PH 分布, F 为其分布函数, 对于 $r < 1$,

$$\sum_{n=0}^{\infty} (1-r)r^{n-1} F^{(n)}$$

为 PH 分布, 其中 $F^{(n)}$ 为 F 的 n 重卷积。

以上性质的证明均留给读者作为练习。

由于 PH -分布便于上机计算与分析等特点, 它已在排队系统, 制造系统, 通信网络, 计算机网络等领域有广泛的应用。

§ 3.7 首达目标模型与其它模型的关系

本节考虑定义在状态空间 S 为有限集的马氏链 $\{X_n, n \geq 0\}$ 上系统的总报酬 (或某个性能指标) 的矩与分布及其拉氏变换问题。设 $H \subset S$ 为目标集, $\bar{H} = S - H$ 为系统的工作集, 设 $r(i)$ 是定义在 S 上的非负有穷值函数, $r(i)$ 可理解为系统在 i 状态在单位时段的报酬 ($r(i)$ 亦可称为该系统的某个性能指标函数)。为方便且不失一般性, 当 $i \in H$ 时, 规定 $r(i) \equiv 0$ 。

令:

$$\tau_H = \begin{cases} \min\{n : n \geq 0, X_n \in H\}, & \{n : n \geq 0, X_n \in H\} \neq \emptyset, \\ \infty, & \{n : n \geq 0, X_n \in H\} = \emptyset, \end{cases}$$

$$W_0 = \sum_{n=0}^{\tau_H} r(X_n), \quad W_1 = \sum_{n=1}^{\tau_H} r(X_n).$$

于是 τ_H 表示首次到达目标集时间, W_0 表示从 0 时刻到进入目标集之前的总报酬 (或性能指标), 它是定义于 $\{X_n, n \geq 0\}$ 上的可加泛函。由于 $r(X_n) \geq 0 (n \geq 0)$, 故 W_0, W_1 均

是非负随机变量. 记

$$\begin{aligned}\mu_i^{(k)} &= E(W_0^k | X_0 = i), \quad k \geq 1, i \in \overline{H}; \\ F_i(t) &= P(W_0 \leq t | X_0 = i), \quad t \geq 0, i \in \overline{H}; \\ \phi_i(\lambda) &= \int_0^\infty e^{-\lambda t} dF_i(t), \quad \lambda \geq 0, i \in \overline{H}.\end{aligned}$$

记 $r_i^{(0)} = \mu_i^{(0)} = 1$. 令 $r_i = r_i^{(1)} = r(i)$, 及

$$r_i^{(k)} = \sum_{l=0}^{k-1} (-1)^{k-1-l} C_k^l r_i^{k-l} \mu_i^{(l)} \quad (k \geq 1).$$

以 $\mathbf{r}^{(k)}$, $\mu^{(k)}$ 及 $\phi(\lambda)$ 分别表示分量为 $r_i^{(k)}$, $\mu_i^{(k)}$ 及 $\phi_i(\lambda)$ ($i \in \overline{H}$) 的列向量. 则有如下定理:

定理 3.7.1 对任意 $k \geq 1$, $\mu^{(k)}$ 满足方程组

$$\mu^{(k)} = \mathbf{r}^{(k)} + \mathbf{P}\mu^{(k)}. \quad (3.7.1)$$

其中 $\mathbf{P} = (p_{ij})_{\overline{H} \times \overline{H}}$, $i, j \in \overline{H}$.

证: 注意到当 $X_0, X_1 \in S$ 时 $W_0^k = \sum_{l=0}^{k-1} C_k^l r_i^{k-l} W_1^l + W_1^k$, 然后用类似于定理 3.6.3 的证明方法即可得 (3.7.1). \square

设 $\mathbf{Y} = (y_1, y_2, \dots, y_p)^T$ 为 \overline{H} 上的未知列向量, 有如下定理:

定理 3.7.2 若 \overline{H} 为瞬时态集, 则 $\mu^{(k)}$ ($k \geq 1$) 是下列方程组

$$\mathbf{Y} = \mathbf{r}^{(k)} + \mathbf{P}\mathbf{Y} \quad (3.7.2)$$

的唯一非负有界解, 且

$$\mu^{(k)} = \sum_{n=0}^{\infty} \mathbf{P}^{(n)} \cdot \mathbf{r}^{(k)} \quad (3.7.3)$$

证: 由 (3.7.1) 式知 $\mu^{(k)}$ 是 (3.7.2) 的一个非负有界解, 以下只需证唯一性.

设 $\mathbf{V}^{(k)}$ 是 (3.7.2) 的另一非负有界解, 即

$$\mathbf{V}^{(k)} = \mathbf{r}^{(k)} + \mathbf{P}\mathbf{V}^{(k)}.$$

由上式及 (3.7.1) 式, 有

$$\mathbf{V}^{(k)} - \mu^{(k)} = \mathbf{P}(\mathbf{V}^{(k)} - \mu^{(k)}). \quad (3.7.4)$$

重复利用 (3.7.4), 有

$$\mathbf{V}^{(k)} - \mu^{(k)} = \mathbf{P}(\mathbf{V}^{(k)} - \mu^{(k)}) = \mathbf{P}^{(2)}(\mathbf{V}^{(k)} - \mu^{(k)}) = \dots = \mathbf{P}^{(n)}(\mathbf{V}^{(k)} - \mu^{(k)}).$$

因 \overline{H} 为瞬时态集, 故 $\forall i, j \in \overline{H}, \lim_{n \rightarrow \infty} p_{ij}^{(n)} = 0$ 且 $\mathbf{P}^{(n)} \rightarrow \mathbf{0}$. 故

$$\mathbf{V}^{(k)} - \mu^{(k)} = \lim_{n \rightarrow \infty} \mathbf{P}^{(n)}(\mathbf{V}^{(k)} - \mu^{(k)}) = \mathbf{0}.$$

3.7 首达目标模型与其它模型的关系

所以

$$\mathbf{V}^{(k)} = \mu^{(k)}.$$

且

$$(\mathbf{I} - \mathbf{P})^{-1} = \sum_{n=0}^{\infty} \mathbf{P}^{(n)}.$$

存在, 于是由 (3.7.1) 式可得 (3.7.3) 式. \square

推论 1 记 $\|\mu^{(1)}\| = \max_i |\mu_i^{(1)}|$, $\|\mathbf{r}\| = \max_i |r_i|$, 则当 $\rho < 1$ 时, 有

$$\|\mu^{(1)}\| \leq \frac{1}{1-\rho} \|\mathbf{r}\|. \quad \square$$

记

$$\begin{aligned} \mathbf{P}_\lambda &= (p_{ij} \exp(-\lambda r_i)), \quad i, j \in \overline{H}, \\ b_i(\lambda) &= \sum_{j \in H} p_{ij} \exp(-\lambda r_i), \\ \mathbf{b}(\lambda) &= (b_1(\lambda), b_2(\lambda), \dots, b_p(\lambda))^T. \end{aligned}$$

则有如下定理:

定理 3.7.3 对 $\lambda \geq 0$, $\phi(\lambda)$ 是下列方程组

$$\mathbf{Y} = \mathbf{b}(\lambda) + \mathbf{P}_\lambda \mathbf{Y} \quad (3.7.5)$$

唯一的非负有界解.

证: 先证 $\phi(\lambda)$ 是 (3.7.5) 式的解. 因

$$\begin{aligned} F_i(t) &= P(W_0 \leq t | X_0 = i) \\ &= \sum_{j \in \overline{H}} p_{ij} P(W_1 \leq t - r_i | X_1 = j) + \sum_{j \in H} p_{ij} P(r_i \leq t | X_1 = j). \end{aligned}$$

故

$$F_i(t) = \sum_{j \in \overline{H}} p_{ij} F_j(t - r_i) + \sum_{j \in H} p_{ij} P(r_i \leq t | X_1 = j). \quad (3.7.6)$$

从而

$$\phi_i(\lambda) = \sum_{j \in \overline{H}} p_{ij} \exp(-\lambda r_i) \phi_j(\lambda) + \sum_{j \in H} p_{ij} \exp(-\lambda r_i) \quad (i \in \overline{H}). \quad (3.7.7)$$

即

$$\phi(\lambda) = \mathbf{b}(\lambda) + \mathbf{P}_\lambda \phi(\lambda). \quad (3.7.8)$$

下面证明唯一性, 只要注意到: $\rho(\mathbf{P}_\lambda) < \sum_{j \in \overline{H}} p_{ij} e^{-\lambda r_i} < 1$, 再用类似于定理 3.7.2 的唯一性证明过程, 便知 $\phi(\lambda)$ 是 (3.7.5) 式唯一的非负有界解. \square

因为 $0 < \phi_i(\lambda) < 1$, 显然有下述结果:

推论 对 $\lambda \geq 0$, 有

$$\phi(\lambda) = \sum_{n=0}^{\infty} \mathbf{P}_{\lambda}^n \mathbf{b}(\lambda). \quad \square \quad (3.7.9)$$

首达目标模型不仅有广泛的应用背景, 同时它在理论上是最重要的基本模型之一, 因为其它许多模型均可化为该模型来处理. 下面着重以折扣依赖于历史模型为例.

马氏链折扣依赖于历史的 (可加泛函) 模型

设 $X = \{X_n, n \geq 0\}$ 为马氏链, 状态空间为 $S = \{1, 2, \dots, m\}$ 一步转移概率矩阵为 $\mathbf{P} = (p_{ij})$.

令 $r: S \rightarrow \mathbb{R}^+$, $r(i)$ 表示系统在 i 状态的性能指标. 折扣因子 $\beta: S \rightarrow [0, 1)$, $\beta(i)$ 与状态有关. 记 $\beta(i) = \exp\{-\bar{\beta}(i)\}$, 其中 $\bar{\beta}(i) > 0, \forall i \in S$. 考虑折扣依赖于历史的可加性能泛函

$$\left\{ \begin{array}{l} \xi_k = \sum_{n=k}^{\infty} \left(\prod_{l=k}^{n-1} \beta(X_l) \right) r(X_n) = \sum_{n=k}^{\infty} \left(\exp\left\{ -\sum_{l=k}^{n-1} \bar{\beta}(X_l) \right\} \right) r(X_n), \\ m_k(i) = E(\xi_0^k | X_0 = i), \quad r_1(i) = r(i), \quad r_k(i) = \sum_{l=0}^{k-1} (-1)^{k+1-l} C_k^l r^{k-l}(i) m_l(i), \\ p_{ij}(k) = \beta^k(i) p_{ij}, \quad i, j \in S, k \geq 1, \\ \mathbf{m}_k = (m_k(i), i \in S)^T, \quad \mathbf{r}_k = (r_k(i), i \in S)^T, \quad \mathbf{P}(k) = (p_{ij}(k))_{i,j \in S} \end{array} \right. \quad (3.7.10)$$

, 式中约定 $\prod_{l=0}^{-1} \beta(X_l) = 1$.

定理 3.7.4 $\forall k \geq 1$, \mathbf{m}_k 满足

$$\mathbf{m}_k = \mathbf{r}_k + \mathbf{P}(k) \mathbf{m}_k. \quad (3.7.11)$$

证: 类似于定理 3.7.1 的证明. \square

注意到当 $\beta(i) < 1, \forall i \in S$ 时, 有以下推论:

推论 \mathbf{m}_k 是下列非负方程

$$\mathbf{X} = \mathbf{r}_k + \mathbf{P}(k) \mathbf{X}$$

的唯一非负最小解, 且

$$\mathbf{m}_k = \sum_{n=0}^{\infty} \mathbf{P}^n(k) \mathbf{r}_k. \quad \square \quad (3.7.12)$$

由上面讨论可知, 只要已知 r, β 与 $\mathbf{P} = (p_{ij})$, 可由 (3.7.12) 式逐次求得 $\mathbf{m}_1, \mathbf{r}_1,$

$\mathbf{m}_2, \mathbf{r}_2, \dots, \mathbf{m}_k, \mathbf{r}_k, \dots$.

从方程 (3.7.1) 和 (3.7.11) 可以看出, 首达目标模型的 k 阶矩 μ_k 与折扣依赖于历史模型中的 k 阶矩所满足的方程组极为相似. 自然要问: 对于给定的马氏链的折扣依赖于

练习题

历史模型的 $k(k \geq 1)$ 阶矩问题, 能否构造一马氏链, 使其首达目标的一阶矩恰好等于前者的 k 阶矩? 回答是肯定的.

定理 3.7.5 对于由 (3.7.10) 式给出的折扣依赖于历史模型的 k 阶矩向量 $\mathbf{m}_k(k \geq 1)$ 必可构造一相应的首达目标模型, 使得该模型的一阶矩向量恰好等于 \mathbf{m}_k .

证: 构造相应的首达目标模型. 设新马氏链为 $\tilde{X} = \{\tilde{X}_n, n \geq 0\}$, 其状态空间为 $\tilde{S} = S \cup \{\delta\}$, 一步转移概率矩阵为 $\tilde{\mathbf{P}}(k) = (\tilde{p}_{ij}(k))$, $i, j \in \tilde{S}$, 指标函数为 $\tilde{r}_k : \tilde{S} \rightarrow \mathbb{R}^+$, 其中

$$\left\{ \begin{array}{l} \tilde{p}_{ij}(k) = \begin{cases} \beta^k(i)p_{ij}, & i, j \in S, \\ 1 - \sum_{j \in S} \tilde{p}_{ij}(k), & i \in S, j = \delta, \\ 1, & i = j = \delta, \\ 0, & i = \delta, j \in S, \end{cases} \\ \tilde{r}_k(i) = \begin{cases} r_k(i), & i \in S, \\ 0, & i = \delta. \end{cases} \\ \tilde{T}_\delta = \inf\{n : n \geq 0, \tilde{X}_n = \delta\}, \\ \tilde{\xi}_0(k) = \sum_{n=0}^{\tilde{T}_\delta} \tilde{r}_k(\tilde{X}_n), \quad \tilde{\mu}_1(i, k) = E(\tilde{\xi}_0(k) | \tilde{X}_0 = i), \quad i \in S, \\ \tilde{\mu}_1(k) = (\tilde{\mu}_1(i, k), i \in S). \end{array} \right. \quad (3.7.13)$$

式中 \tilde{T}_δ 表示首达 δ 的时间, $\tilde{\mu}_1(k)$ 表示首达目标一阶矩向量. 因 $\tilde{p}_{i\delta}(k) > 0, \forall i \in S$ 且 $\tilde{p}_{\delta\delta}(k) = 1$, 从而 S 与 δ 对 $\tilde{X} = \{\tilde{X}_n, n \geq 0\}$ 而言分别是瞬态集与吸收态. 不难验证,

$$\tilde{\mu}_1(k) = \mathbf{r}_k + \mathbf{P}(k)\tilde{\mu}_1(k),$$

且是方程组 $\mathbf{X} = \mathbf{r}_k + \mathbf{P}(k)\mathbf{X}$ 的唯一非负最小解. 故

$$\tilde{\mu}_1(k) = \mathbf{m}_k.$$

这说明由 (3.7.10) 式定义的折扣依赖于历史模型的 k 阶矩 ($k \geq 1$ 任意固定) 与由 (3.7.13) 式定义的首达目标模型的一阶矩相等. \square

读者不难看出, 在 § 3.6 中讨论的达到次数的矩问题及其它许多问题亦可化为首达目标模型的一阶矩问题.

练习题

3.1 设马氏链 $\{X_n, n \geq 0\}$, $S = \{1, 2, 3\}$, $X_0 = 3$, $T = \min\{n : n \geq 1, X_n = 1\}$ 的转移矩阵

问别为：

$$\mathbf{P}_1 = \begin{bmatrix} 1 & 0 & 0 \\ \frac{1}{3} & 0 & \frac{2}{3} \\ 0 & \frac{1}{3} & \frac{2}{3} \end{bmatrix}, \quad \mathbf{P}_2 = \begin{bmatrix} \frac{1}{3} & \frac{2}{3} & 0 \\ \frac{1}{3} & 0 & \frac{2}{3} \\ 0 & \frac{1}{3} & \frac{2}{3} \end{bmatrix}, \quad \mathbf{P}_3 = \begin{bmatrix} 0 & \frac{1}{3} & \frac{2}{3} \\ \frac{1}{3} & 0 & \frac{2}{3} \\ \frac{1}{3} & \frac{2}{3} & 0 \end{bmatrix}.$$

1. 对 \mathbf{P}_1 , 求 $E(X_2), E(X_2|X_1), E(X_3|X_2), \pi_i(2) = P(X_2 = i), i \in S$;
2. 对 \mathbf{P}_2 , 求 $P(T = k|X_0 = 3), 1 \leq k \leq 3$ 及 $E(T \wedge 4|X_0 = 3)$;
3. 对 \mathbf{P}_3 , 求 T_{11} 的分布律及 ET_{11} .

3.2 设

$$\mathbf{P} = \begin{bmatrix} 1-a & a \\ b & 1-b \end{bmatrix}, \quad 0 < a, b < 1.$$

证明

$$\mathbf{P}^n = \frac{1}{a+b} \begin{bmatrix} b & a \\ b & a \end{bmatrix} + \frac{(1-a-b)^n}{a+b} \begin{bmatrix} a & -a \\ -b & b \end{bmatrix}.$$

3.3 设 $S = \{1, 2, \dots, m\}$ 有限, 令

$$p_{ij}^{(0)} = \begin{cases} 1, & j = i, \\ 0, & j \neq i, \end{cases} \quad i, j \in S,$$

定义转移概率母函数 $\phi_{ij}(z) = \sum_{n=0}^{\infty} p_{ij}^{(n)} z^n, |z| < 1, i, j \in S$ 母函数矩阵 $\Phi(z) = (\phi_{ij}(z))$. 证明

$$\Phi(z) = (\mathbf{I} - z\mathbf{P})^{-1} = \mathbf{I} + z\mathbf{P} + z^2\mathbf{P}^2 + \dots + z^n\mathbf{P}^n + \dots.$$

3.4 一个国家在稳定经济条件下它的出口商品能够用三状态的马氏链描述如下：状态空间 $S = \{+1, 0, -1\}$; +1: 今年比去年增长 $\geq 5\%$; 0: 波动低于 5% ; -1: 今年比去年减少 $\geq 5\%$. 由以往的统计数据求得转移矩阵为

$$\begin{array}{c} \begin{matrix} & +1 & 0 & -1 \end{matrix} \\ \begin{matrix} +1 \\ 0 \\ -1 \end{matrix} \begin{bmatrix} 0.8 & 0.2 & 0 \\ 0.35 & 0.30 & 0.35 \\ 0 & 0.40 & 0.60 \end{bmatrix} \end{array}.$$

104

试求每个状态的平均返回时间, 并比较在稳定经济条件下增长趋势与减少趋势的期望长度.

练习题

3.5 水库供水按其水位分为下列 5 个状态：“1” – 危险水平；“2” – 缺水；“3” – 刚够；“4” – 较好；“5” – 充裕. $S = \{1, 2, 3, 4, 5\}$, 由已有数据求得相邻时间周期的转移矩阵为

$$\mathbf{P} = \begin{bmatrix} 0.1 & 0.1 & 0.3 & 0.5 & 0 \\ 0.3 & 0.2 & 0.2 & 0.2 & 0.1 \\ 0.1 & 0.2 & 0.4 & 0.2 & 0.1 \\ 0 & 0.1 & 0.2 & 0.4 & 0.3 \\ 0 & 0.1 & 0.1 & 0.4 & 0.4 \end{bmatrix}$$

试求出危险水平的平均时间长度 (即求 $\mu_{11} = \mu_1$).

3.6 在 § 3.1 中例 3(a) 离散时间排队模型中, $n+1$ 时刻等待服务的顾客数 $X_{n+1} = (X_n - 1)^+ + \xi_n$, 其中 $\{\xi_n, n \geq 0\}$ 独立同分布, 且 $P(\xi_n = k) = a_k, k \in \mathbb{N}$. ξ_n 表示第 n 周期到达的顾客数, $y^+ = \max(0, y)$. 试证明当 $\sum_{k=0}^{\infty} k a_k < 1$ 时, 存在平稳分布, 并求平衡时等待顾客的平均队长.

3.7 设马氏链 $\{X_n, n \geq 0\}, S = \{1, 2, 3\}, \mathbf{P}$ 如下

$$\mathbf{P} = \begin{bmatrix} 0.5 & 0.4 & 0.1 \\ 0.3 & 0.4 & 0.3 \\ 0.2 & 0.3 & 0.5 \end{bmatrix}$$

1. 求平稳分布 $\pi = (\pi_1, \pi_2, \pi_3)$ 及 $\lim_{n \rightarrow \infty} \mathbf{P}^n$;
2. 当初始分布 $\pi(0)$ 是怎样分布时, 此马氏链是平稳序列? 并求 EX_n 及 DX_n .

3.8 设

$$S = \{1, 2, 3\}, \quad \mathbf{P} = \begin{bmatrix} \frac{1}{2} & \frac{1}{4} & \frac{1}{4} \\ 0 & \frac{3}{4} & \frac{1}{4} \\ 0 & 0 & 1 \end{bmatrix},$$

求

1. T_{13} 的分布律及 ET_{13} ;
2. $f_{ii}(i = 1, 2, 3)$;
3. $n \rightarrow \infty$ 时 $p^n \rightarrow ?$.

3.9 考虑下列随机游动

$$\begin{aligned} p_{i,i+1} &= p, \quad 0 < p < 1, \\ p_{i,i-1} &= q = 1 - p, \quad i = 1, 2, \dots, r-1, \\ p_{00} &= p_{rr} = 1. \end{aligned}$$

X_n 表示 n 时刻质点的位置. 当 $k=1, r=3$ 时, 求:

$$d(k) = P\{X_n = r \cup X_n = 0 \text{ 存在 } n \geq 1 | X_0 = k\}, \quad 0 \leq k \leq r.$$

3.10 一马氏链 $\{X_n, n \geq 0\}$ 的 $S = \{0, 1, 2, \dots, N\}$, 转移概率为

$$p_{ij} = \begin{cases} \mu_i, & j = i - 1, \\ \lambda_i, & j = i + 1, \\ 1 - \lambda_i - \mu_i, & j = i, \\ 0, & |j - i| > 1, \end{cases} \quad i, j \in S$$

且 $\mu_0 = \lambda_0 = \mu_N = \lambda_N = 0, 0 < \mu_i < 1, 0 < \lambda_i < 1, 1 \leq i \leq N-1, X_0 = k$, 求

1. $P(X_n = 0, \text{某个 } n \geq 0 | X_0 = k)$ 及 $P(X_n = N, \text{某个 } n \geq 0 | X_0 = k)$;
2. ET_{k0} 及 ET_{kN} .

3.11 设马氏链 $\{X_n, n \geq 0\}$ 的 $S = \{0, 1, 2, \dots, N\}$, 转移概率为 $p_{ij} = C_N^j \pi_i^j (1 - \pi_i)^{N-j}, 0 \leq i, j \leq N$ 其中 $\pi_i = \frac{1 - e^{-2ai/N}}{1 - e^{-2a}}, a > 0$ (注意 “0” 与 “N” 状态是吸收状态).

1. 证明 $\{e^{-2aX_n}, n \geq 0\}$ 是鞅, 即

$$E(e^{-2aX_{n+1}} | X_0, X_1, \dots, X_n) = e^{-2aX_n}, \quad n \in \mathbb{N};$$

2. 证明

$$P_N(k) \triangleq P(X_n = N, \text{对某个 } n \geq 0 | X_0 = k) = \frac{1 - e^{-2ak}}{1 - e^{-2aN}}.$$

3.12 设 j 为非常返状态, 证明对任意 $i \in S$, 有

$$\sum_{n=1}^{\infty} p_{ij}^{(n)} = \frac{f_{ij}}{1 - f_{jj}} < \infty.$$

3.13 设 $\{X_n, n \geq 0\}$ 是独立同分布且 $P(X_i = k) = \alpha_k \geq 0, k \in \mathbb{N}_0, \sum_{k=0}^{\infty} \alpha_k = 1$. 如 $X_n > \max(X_1, X_2, \dots, X_{n-1})$, (其中 $X_0 = -\infty$), 则说 n 时刻创一新记录, 且称 X_n 为记录值. 记 R_i 为第 i 回的纪录值. 试说明 $\{R_i, i \geq 1\}$ 是一马氏链并求其转移概率.

3.14 设有两串独立的贝努里 (Bernoulli) 试验序列 X_1, X_2, \dots 及 Y_1, Y_2, \dots , 它们成功的概率分别记为 p_1 与 p_2 , 即 $P(X_i = 1) = 1 - P(X_i = 0) = p_1, P(Y_i = 1) = 1 - P(Y_i = 0) = p_2$. $\{X_n, n \geq 1\}$ 与 $\{Y_n, n \geq 1\}$ 独立. 为决定是否 $p_1 > p_2$ 或 $p_2 \geq p_1$, 我们利用下列检验: 选取某个正整数 M 使得

$$\text{或者} \quad X_1 + X_2 + \dots + X_n \geq Y_1 + Y_2 + \dots + Y_n = M,$$

$$\text{或者} \quad X_1 + X_2 + \dots + X_n - (Y_1 + Y_2 + \dots + Y_n) = -M.$$

练习题

若试验结果是前一情况发生, 则判定 $p_1 > p_2$; 若是后一情况发生, 则判定 $p_2 \geq p_1$. 记

$$N = \min\{n : n \geq 1, X_1 + X_2 + \cdots + X_n - (Y_1 + Y_2 + \cdots + Y_n) = \pm M\}.$$

试证明

1. 在 $p_1 > p_2$ 条件下, 经试验误判 $p_2 > p_1$ 的概率为 $\frac{1}{1+\lambda^M}$, 其中 $\lambda = \frac{p_1(1-p_2)}{p_2(1-p_1)}$;
- 2.

$$EN = \frac{M(\lambda^M - 1)}{(p_1 - p_2)(\lambda^M + 1)}.$$

3.15 设非负减序列 $1 = b_0 \geq b_1 \geq b_2 \geq \cdots$, 令 $\beta_n = b_n(b_0 + b_1 + \cdots + b_n)^{-1}$, $\sigma_n = b_0 + b_1 + \cdots + b_n$. 考虑马氏链 $\{X_n, n \geq 0\}$ 的转移概率为

$$p_{ij} = \begin{cases} \frac{b_i}{b_i}(\beta_i - \beta_{i+1}), & j \leq i, \\ \frac{\beta_{i+1}}{\beta_i}, & j = i+1, \\ 0, & \text{其它.} \end{cases}$$

1. 证 $p_{00}^n = \sigma_n^{-1}$;
2. 该马氏链是非常返链, 当且仅当

$$\sum_{n=0}^{\infty} \frac{1}{\sigma_n} < \infty.$$

3.16 $\{X_n, n \geq 0\}$ 为离散分支过程 (见 § 3.1.2 例 4). 令 $\mu = E\xi_i, \sigma^2 = D\xi_i$.

1. 说明 “0” 状态是吸收态, 而其它状态是非常返态;
2. 证明

$$D(X_n | X_0 = 1) = \begin{cases} \sigma^2 \mu^{n-1} \frac{\mu^n - 1}{\mu - 1}, & \mu \neq 1, \\ n\sigma^2, & \mu = 1. \end{cases}$$

3.17 设 $\{X_n, n \geq 0\}$ 是 M.C., 证: $\forall n \geq 1, i, j \in S, B_k \subset S, 0 \leq k \leq n-1$, 有 $P(X_{n+1} = j | X_k \in B_k, 0 \leq k \leq n-1, X_n = i) = P(X_{n+1} = j | X_n = i)$.

3.18 设 $\{Y_n, n \geq 0\}$ iid, $P(Y_n = 1) = p \geq 0, P(Y_n = -1) = q = 1 - p \geq 0$. 令 $X_0 = Y_0 = i, X_N = \sum_{k=1}^n Y_k, n \geq 1, T_i \triangleq \min\{n : n \geq 0, X_0 = i, X_n = 0 \text{ 或 } X_n = b\}$, 其中 b 为正整数, $0 \leq i \leq b$.

1. 当 $i = 1, b = 3$ 时, 求 $P(T_1 = k | X_0 = 1), k \in \mathbb{N}$ 及 $P(X_{T_1} = 3 | X_0 = 1)$;
2. 当 $i = 2, b = 5$ 时, 求 $P(T_2 = k | X_0 = 2), k \in \mathbb{N}$ 及 $P(X_{T_2} = 5 | X_0 = 2)$.

3.19 设 $\{Y_n, n \geq 0\}$ iid, $P(Y_n = 1) = p \geq 0, P(Y_n = -1) = q = 1 - p \geq 0$. 令 $X_0 = Y_0 = i, X_N = \sum_{k=1}^n Y_k, n \geq 1, T_{0k} \triangleq \min\{n : n > 0, X_0 = 0, X_n = k\}, X'_n = X_{T_{01}+n}, T'_{12} = \min\{n : n > 0, X'_0 = 1, X'_n = 2\}$.

1. 当 $p > q$ 时, 证 $\{X_n, n \geq 0\}$ 与 $\{X'_n, n \geq 0\}$ 具有相同的 $\mathbf{P} = (p_{ij})$;

2. 证 $\{T_{01} = 5\}$ 与 $\{T'_{12} = 3\}$ 独立, T_{01} 与 T'_{12} iid.

3. 试用母函数方法求 T_{01} 的分布律, $P(T_{01} = +\infty) = ?$;

4. 当 $p - q > 0$ 时, 证明 $ET_{01} < \infty$.

3.20 设 $\{X_n, n \geq 0\}$ 为 M.C., 状态空间 $S = \{1, 2, 3\}$, $S_0 = \{2, 3\}$ 。一步转移概率矩阵 $P = (p_{ij})$ 如下: $p_{11} = 5/8, p_{12} = 2/8, p_{13} = 1/8, p_{21} = 2/6, p_{22} = 3/6, p_{23} = 1/6, p_{31} = 3/4, p_{32} = 1/4, p_{33} = 0, X_0 = 1$, 令: $T_1 = \min\{n : n > 0, X_n \in S_0\}, \tau_1 = \min\{n : n > T_1, X_n = 1\}, T_n = \min\{n : n > \tau_{n-1}, X_n \in S_0\}, \tau_n = \min\{n : n > T_n, X_n = 1\}, n \geq 2, N(t) = \sum_{m=1}^{\infty} I_{(T_m \leq t)}$.

1. 试问 $\lim_{n \rightarrow \infty} p_{ij}^n$ 与 $\lim_{n \rightarrow \infty} E(X_n | X_0 = 1)$ 是否存在? 若存在, 求之;

2. T_1 与 τ_1 关于 $\{X_n, n \geq 0\}$ 是否是停时? 说明理由;

3. 求 $P(T_1 = k), k \in N, ET_1, E\tau_1$;

4. 求 $P(N(3) = k), P(N(4) = 2)$.

3.21 设 $\{X_n, n \geq 0\}$ 为不可约的 M.C., 状态空间 $S = \{1, 2, 3\}$ 。 $P = (p_{ij})$ 为一步转移概率矩阵, 记: $T = \min\{n : n > 0, X_n = 3\}, \tau = \min\{n : n > 0, X_n = 1\}$. 若已知 $a_k(i) = E(T^k | X_0 = i), i \in \{1, 2\}, 1 \leq k \leq 3, b_k(i) = E(\tau^k | X_0 = i), i \in \{2, 3\}, 1 \leq k \leq 3$.

试讨论在什么条件下能够用 $a_k(i), i \in \{1, 2\}, 1 \leq k \leq 3$ 及 $b_k(i), i \in \{2, 3\}, 1 \leq k \leq 3$ 表示 $P = (p_{ij}), (i, j \in S)$? 给出适当的条件及它的具体表示.

第四章 离散鞅引论

鞅 (Martingale) 论目前已成为研究概率论理论及应用概率论和其它随机过程的有力工具. 在统计, 序贯决策, 最优控制, 随机微分方程等方面均得到了广泛应用. 鞅论的发展与现今的竞争社会是分不开的. 有奖彩票, 保险, 投资建设等均与鞅论有关.

§ 4.1 定义与例子

定义 过程 $\{X_n, n \geq 0\}$ 是鞅, 如果 $\forall n \geq 0$, 有

$$1^\circ E|X_n| < \infty,$$

$$2^\circ E(X_{n+1} | X_0, X_1, \dots, X_n) = X_n \text{ a.s. (几乎处处).}$$

□

鞅的背景来源于公平赌博. 上式表明, 如第 n 次赌后资金为 X_n , 则第 $n+1$ 赌博后的平均资金恰等于 X_n , 即每次赌博胜负机会均等.

有时 $\{X_n, n \geq 0\}$ 不能直接观察, 而只能观察另一过程 $\{Y_n, n \geq 0\}$. 故我们作如下定义:

定义 设有二过程 $\{X_n, n \geq 0\}$ 及 $\{Y_n, n \geq 0\}$, 称 $\{X_n, n \geq 0\}$ 关于 $\{Y_n, n \geq 0\}$ 是鞅, 如果

$$1^\circ E|X_n| < \infty,$$

$$2^\circ E(X_{n+1} | Y_0, Y_1, \dots, Y_n) = X_n \text{ a.s. (几乎处处)}$$

□

解释: (i) 因为 $X_n = E(X_{n+1} | Y_0, \dots, Y_n)$ 是 (Y_0, Y_1, \dots, Y_n) 的函数, 故有 $E(X_n | Y_0, Y_1, \dots, Y_n) = X_n$. (ii) $EX_{n+1} = E[E(X_{n+1} | Y_0, \dots, Y_n)] = EX_n = EX_0$. 这说明鞅 $\{X_n, n \geq 0\}$ 在任何时刻的期望值均相等.

下面介绍一些鞅的典型例子.

例 1 独立同分布随机变量之和

设 $Y_0 = 0, \{Y_n, n \geq 1\}$ 独立同分布, $EY_n = 0, E|Y_n| < \infty, X_0 = 0, X_n = \sum_{i=1}^n Y_i$, 则 $\{X_n, n \geq 0\}$ 关于 $\{Y_n, n \geq 0\}$ 是鞅.

证: 因为

$$E|X_n| = E\left|\sum_{i=1}^n Y_i\right| < \infty,$$

$$E(X_{n+1} | Y_0, Y_1, \dots, Y_n) = E(X_n + Y_{n+1} | Y_1, \dots, Y_n)$$

$$= E(X_n | Y_0, \dots, Y_n) + E(Y_{n+1} | Y_0, \dots, Y_n) = X_n. \quad \square$$

例 2 和的方差

109

设 $Y_0 = 0, \{Y_n, n \geq 1\}$ 独立同分布, $EY_n = 0, EY_n^2 = \sigma^2, X_0 = 0, X_n = (\sum_{k=1}^n Y_k)^2 - n\sigma^2$, 则 $\{X_n, n \geq 0\}$ 关于 $\{Y_n, n \geq 0\}$ 是鞅.

证： 因为

$$\begin{aligned} E|X_n| &= E\left| \left(\sum_{k=1}^n Y_k \right)^2 - n\sigma^2 \right| \leq E\left| \left(\sum_{k=1}^n Y_k \right)^2 \right| + n\sigma^2 \\ &= E\left(\sum_{k=1}^n Y_k^2 + \sum_{i \neq j} Y_i Y_j \right) + n\sigma^2 = 2n\sigma^2 < \infty; \end{aligned}$$

$$\begin{aligned} E(X_{n+1}|Y_0, \dots, Y_n) &= E\left[\left\{ \left(Y_{n+1} + \sum_{k=1}^n Y_k \right)^2 - (n+1)\sigma^2 \right\} | Y_0, \dots, Y_n \right] \\ &= E\left[\left\{ Y_{n+1}^2 + 2Y_{n+1} \sum_{k=1}^n Y_k + \left(\sum_{k=1}^n Y_k \right)^2 - (n+1)\sigma^2 \right\} | Y_0, \dots, Y_n \right] \\ &= E[Y_{n+1}^2 | Y_0, \dots, Y_n] + 2E\left(Y_{n+1} \sum_{k=1}^n Y_k | Y_0, \dots, Y_n \right) + E(X_n | Y_0, \dots, Y_n) - \sigma^2 \\ &= EY_{n+1}^2 + 2E(Y_{n+1} | Y_0, \dots, Y_n) \left(\sum_{k=1}^n Y_k \right) + X_n - \sigma^2 \\ &= \sigma^2 + 0 + X_n - \sigma^2 = X_n. \quad \square \end{aligned}$$

由上两例知, 由独立同分布随机变量的和或者和的方差所构成的序列都可以构造鞅, 那么更一般的结论呢?

例 3 一般和

设 $\{Y_n, n \geq 0\}$ 为一随机序列, $Z_i = g_i(Y_0, \dots, Y_i)$, g_i 为一般函数. 函数 f 满足 $E|f(Z_k)| < \infty$. $a_k(y_0, \dots, y_{k-1}) (k \geq 0)$ 为 k 元有界实函数, 即

$$|a_k(y_0, \dots, y_{k-1})| \leq A_k, \quad \forall y_0, \dots, y_{k-1}.$$

约定:

$$a_0(Y_{-1}) = a_0, \quad E[f(Z_0)|Y_{-1}] = E[f(Z_0)].$$

令

$$X_n = \sum_{k=0}^n \{f(Z_k) - E[f(Z_k)|Y_0, Y_1, \dots, Y_{k-1}]\} \cdot a_k(Y_0, \dots, Y_{k-1}),$$

可以验证, $\{X_n, n \geq 0\}$ 关于 $\{Y_n, n \geq 0\}$ 是鞅.

证: (i)

$$\begin{aligned} E|X_n| &\leq \sum_{k=0}^n E|\{f(Z_k) - E[f(Z_k)|Y_0, \dots, Y_{k-1}]\} a_k(Y_0, \dots, Y_{k-1})| \\ &\leq \sum_{k=0}^n A_k \{E[|f(Z_k)|] + E\{E[|f(Z_k)| | Y_0, \dots, Y_{k-1}]\}\} \leq \sum_{k=0}^n 2A_k E|f(Z_k)| < \infty. \end{aligned}$$

4.1 定义与例子

(ii) 记

$$B_k = \{f(Z_k) - E[f(Z_k)|Y_0, \dots, Y_{k-1}]\}a_k(Y_0, \dots, Y_{k-1}).$$

则

$$\begin{aligned} E(B_k|Y_0, \dots, Y_{k-1}) &= a_k(Y_0, \dots, Y_{k-1})\{E[f(Z_k)|Y_0, \dots, Y_{k-1}] \\ &\quad - E(E[f(Z_k)|Y_0, \dots, Y_{k-1}]|Y_0, \dots, Y_{k-1})\} \\ &= a_k(Y_0, \dots, Y_{k-1})\{E[f(Z_k)|Y_0, \dots, Y_{k-1}] - E[f(Z_k)|Y_0, \dots, Y_{k-1}]\} = 0 \end{aligned}$$

上式推导中用到了 $a_k(Y_0, \dots, Y_{k-1})$ 是 Y_0, \dots, Y_{k-1} 的函数, $E[f(Z_k)|Y_0, Y_1, \dots, Y_{k-1}]$ 也是 Y_0, \dots, Y_{k-1} 的函数的事实. 由于 $E(B_k|Y_0, \dots, Y_{k-1}) = 0$, 且 X_n 是 Y_0, \dots, Y_n 的函数, 故

$$E(X_{n+1}|Y_0, \dots, Y_n) = E(X_n|Y_0, \dots, Y_n) + E(B_{n+1}|Y_0, \dots, Y_n) = X_n. \quad \square$$

由此可知, 由一个一般的随机序列也可以构造出鞅来. 这是一个有意义的结论. 下面介绍几个具有特殊实用价值的鞅.

例 4 由马氏链导出的鞅

设 $\{Y_n, n \geq 0\}$ 是马氏链 (其状态空间为 S), 具有转移概率矩阵 $\mathbf{P} = (p_{ij})$, f 是 P 的有界右正则序列 (调和函数), 即 $f(i) \geq 0$, 且

$$f(i) = \sum_{j \in S} p_{ij} f(j), \quad |f(i)| < M, \quad i \in S.$$

令 $X_n = f(Y_n)$, 则 $\{X_n, n \geq 0\}$ 关于 $\{Y_n, n \geq 0\}$ 是鞅.

证: 因为

$$E|X_n| < \infty,$$

又由于

$$\begin{aligned} E(X_{n+1}|Y_0, Y_1, \dots, Y_n) &= E(f(Y_{n+1})|Y_0, Y_1, \dots, Y_n) = E(f(Y_{n+1})|Y_n) \quad (\text{由马氏性得到}) \\ &= \sum_{j \in S} f(j)P(Y_{n+1} = j|Y_n) = \sum_{j \in S} f(j)p_{Y_n j} = f(Y_n) = X_n. \end{aligned}$$

因此 $\{X_n, n \geq 0\}$ 关于 $\{Y_n, n \geq 0\}$ 是鞅. \square

例 5 由转移概率特征向量导出的鞅

设 $\{Y_n, n \geq 0\}$ 是一马氏链, $\mathbf{P} = (p_{ij})$. 向量 $\mathbf{f} = [f(0), f(1), \dots, f(i), \dots]$ 称为 \mathbf{P} 的右特征向量, 如果对某个 λ (称 λ 为特征值) 有

$$\lambda f(i) = \sum_{j \in S} p_{ij} f(j), \quad \forall i \in S,$$

且 $E|f(Y_n)| < \infty, \forall n$. 令 $X_n = \lambda^{-n} f(Y_n)$, 则 $\{X_n, n \geq 0\}$ 关于 $\{Y_n, n \geq 0\}$ 是鞅.

证：因为

$$\begin{aligned} E|X_n| &= E|\lambda^{-n} \cdot f(Y_n)| = \lambda^{-n} E|f(Y_n)| < \infty, \\ E(X_{n+1}|Y_0, Y_1, \dots, Y_n) &= E[\lambda^{-n-1} f(Y_{n+1})|Y_0, Y_1, \dots, Y_n] \\ &= \lambda^{-n} \cdot \lambda^{-1} \cdot E[f(Y_{n+1})|Y_n] \\ &= \lambda^{-n} \lambda^{-1} \sum_{j \in S} [f(j) \cdot p_{Y_n j}] = \lambda^{-n} f(Y_n) = X_n. \end{aligned}$$

更一般地，设 $\{Y_n, n \geq 0\}$ 是一离散时间马氏过程，具有转移分布函数

$$F(y|z) = P\{Y_{n+1} \leq y | Y_n = z\}.$$

如果对所有 n , 有 $E|f(Y_n)| < \infty$, 且

$$\lambda f(y) = \int f(z) dF(z|y).$$

则 $\{X_n = \lambda^{-n} f(Y_n), n \geq 0\}$ 是一个鞅. □

例 4 和例 5 将上一章讨论的马氏链与本章的鞅这两个重要的随机过程有机地联系起来了，在实际中这样的应用非常广泛.

例 6 由分支过程构成的鞅

设 $\{Y_n, n \geq 0\}$ 表示一分支过程，并设生成后代分布的均值为 $m < \infty$, 则 $X_n = m^{-n} Y_n$ 关于 $\{Y_n, n \geq 0\}$ 是鞅.

证： 设 $Z^{(n)}(j)$ 为第 n 代的第 j 个个体产生的个体的数目， $Z^{(n)}(i), i = 1, 2, \dots$, 独立同分布， $E\{Z^{(n)}(i)\} = m$, 并设 Y_n 为第 n 代的个体数. 则

$$Y_{n+1} = Z^{(n)}(1) + Z^{(n)}(2) + \dots + Z^{(n)}(Y_n).$$

显然

$$\begin{aligned} E(Y_{n+1}|Y_n) &= E\{Z^{(n)}(1) + \dots + Z^{(n)}(Y_n)|Y_n\} \\ &= E\{Z^{(n)}(1) + \dots + Z^{(n)}(Y_n)\} = Y_n E(Z^{(n)}(1)) = mY_n. \end{aligned}$$

所以， m 是函数 $f(y) = y$ 的特征值. 根据上例的结论，容易导出 $X_n = m^{-n} Y_n$ 关于 $\{Y_n, n \geq 0\}$ 是鞅. □

例 7 Wald 鞅

设 $Y_0 = 0, Y_1, Y_2, \dots, Y_n, \dots$ 独立同分布，且存在一有限矩生成函数 $\phi(\lambda) = E[e^{\lambda Y_n}]$, 对 $\lambda \neq 0$, 令 $X_0 = 1, X_n = \phi^{-n}(\lambda) \exp[\lambda(Y_1 + \dots + Y_n)]$, 那么， $\{X_0, n \geq 0\}$ 关于 $\{Y_n, n \geq 0\}$ 是鞅.

112

证： 首先证明函数 $f(y) = e^{\lambda y}$ 是部分和 $S_n = Y_1 + Y_2 + \dots + Y_n$ 马氏过程的特征函数，对应的特征值是 $\phi(\lambda)$.

4.1 定义与例子

事实上, 若 G 是 Y_n 的分布函数, 则有 $P\{S_{n+1} \leq y | S_n = x\} = G(y - x)$, 因而有

$$\int e^{\lambda y} dG(y - x) = e^{\lambda x} \int e^{\lambda \zeta} dG(\zeta) = e^{\lambda x} \phi(\lambda).$$

由例 5 推广的结论知, 当

$$X_n = \phi^{-n}(\lambda) \cdot f(S_n) = \phi^{-n}(\lambda) \cdot \exp[\lambda S_n]$$

时 $\{X_n, n \geq 0\}$ 关于 $\{S_n, n \geq 0\}$ 是鞅, 即 $\{X_n, n \geq 0\}$ 关于 $\{Y_n, n \geq 0\}$ 是鞅. □

在上例中, 假设 $Y_1, Y_2, \dots, Y_n, \dots$ 独立同分布, 且服从 $N(0, \sigma^2)$, 则

$$\phi(\lambda) = E(\exp(\lambda Y_1)) = \exp\left(\frac{1}{2}\lambda^2 \sigma^2\right),$$

$$X_n = \exp\left\{\lambda(Y_1 + \dots + Y_n) - \frac{n}{2}\lambda^2 \sigma^2\right\}.$$

若令 $\lambda = \frac{\mu}{\sigma^2}$, 得到

$$X_n = \exp\left\{\frac{\mu}{\sigma^2}(Y_1 + Y_2 + \dots + Y_n) - \frac{n\mu^2}{2\sigma^2}\right\}.$$

则 $\{X_n, n \geq 1\}$ 关于 $\{Y_n, n \geq 1\}$ 是鞅.

这是一个非常有用的结论, 因为正态分布是我们经常遇到也长于研究的一种分布.

例 8 似然比构成的鞅

设 $Y_0, Y_1, \dots, Y_n, \dots$ 是独立同分布随机变量序列, f_0 和 f_1 是概率密度函数, 令

$$X_n = \frac{f_1(Y_0) \cdot f_1(Y_1) \cdots f_1(Y_n)}{f_0(Y_0) \cdot f_0(Y_1) \cdots f_0(Y_n)}, \quad n \geq 0.$$

假设 $\forall y, f_0(y) > 0$. 当 Y_n 的概率密度函数为 f_0 时, 则 $\{X_n, n \geq 0\}$ 关于 $\{Y_n, n \geq 0\}$ 是鞅.

证: 因为

$$E|X_n| = E\left[\frac{f_1(Y_0) \cdots f_1(Y_n)}{f_0(Y_0) \cdots f_0(Y_n)}\right] = 1 < \infty.$$

且

$$E(X_{n+1} | Y_0, \dots, Y_n) = E\left[X_n \frac{f_1(Y_{n+1})}{f_0(Y_{n+1})} | Y_0, Y_1, \dots, Y_n\right] = X_n E\left[\frac{f_1(Y_{n+1})}{f_0(Y_{n+1})}\right].$$

由于

$$E\left[\frac{f_1(Y_{n+1})}{f_0(Y_{n+1})}\right] = \int \frac{f_1(y)}{f_0(y)} \cdot f_0(y) dy = \int f_1(y) dy = 1.$$

因此 $\{X_n, n \geq 0\}$ 关于 $\{Y_n, n \geq 0\}$ 是鞅. □

在上例中, 设 f_0 是正态概率密度, 均值为 0, 方差为 σ^2 ; f_1 也是一正态概率密度, 均值为 μ , 方差为 σ^2 , 则

$$\frac{f_1(y)}{f_0(y)} = \exp\left\{\frac{2\mu y - \mu^2}{2\sigma^2}\right\},$$

$$X_n = \exp\left\{\frac{\mu}{\sigma^2}(Y_1 + Y_2 + \dots + Y_n) - \frac{n\mu^2}{2\sigma^2}\right\}.$$

由此可得出与例 7 结尾相同的结论.

例 9 Doob 鞅过程

设 $Y_0, Y_1, \dots, Y_n, \dots$ 是一随机序列. 有一随机变量 $X, E|X| < \infty$, 令

$$X_n = E(X|Y_0, \dots, Y_n),$$

则 $\{X_n, n \geq 0\}$ 是关于 $\{Y_n, n \geq 0\}$ 的鞅, 并称之为 Doob 过程.

证: 因为

$$E|X_n| = E\{|E(X|Y_0, \dots, Y_n)|\} \leq E\{E(|X||Y_0, Y_1, \dots, Y_n)\} = E|X| < \infty,$$

$$E(X_{n+1}|Y_0, \dots, Y_n) = E\{E(X|Y_0, \dots, Y_{n+1})|Y_0, \dots, Y_n\} = E(X|Y_0, \dots, Y_n) = X_n. \quad \square$$

这个例子很“奇特”, 以一系列任意随机变量为条件的条件数学期望构成鞅.

例 10 随机 Radon-Nikodym 导数构成的鞅

设 $Z \sim U[0, 1]$, 即 Z 是 $[0, 1]$ 上均匀分布. 令 $Y_n = \sum_{k=0}^{2^n-1} \frac{k}{2^n} I_{(\frac{k}{2^n} \leq Z \leq \frac{k+1}{2^n})}$, 其中 k 满足

$$\frac{k}{2^n} \leq Z < \frac{k+1}{2^n},$$

即

$$Y_n = \max \left\{ \frac{k}{2^n} : \frac{k}{2^n} \leq Z, \quad k = 0, 1, 2, \dots \right\}.$$

设 f 是 $[0, 1]$ 上的有限函数, 令

$$X_n = 2^n \{f(Y_n + 2^{-n}) - f(Y_n)\},$$

则 $\{X_n, n \geq 0\}$ 关于 $\{Y_n, n \geq 0\}$ 是鞅.

证: 首先注意到, 在 Y_0, Y_1, \dots, Y_n 条件下, Z 服从 $[Y_n, Y_n + 2^{-n})$ 上的均匀分布 ($Y_n \leq Z < Y_n + 2^{-n}$), 且 Y_{n+1} 以相等的概率等于 Y_n 或等于 $Y_n + 2^{-(n+1)}$. 于是有

$$\begin{aligned} E(X_{n+1}|Y_0, \dots, Y_n) &= 2^{n+1} [E(f(Y_{n+1} + 2^{-(n+1)}) - f(Y_{n+1})|Y_0, Y_1, \dots, Y_n)] \\ &= 2^{n+1} \left\{ \frac{1}{2} [f(Y_n + 2^{-(n+1)}) - f(Y_n)] \right. \\ &\quad \left. + \frac{1}{2} [f(Y_n + 2^{-n}) - f(Y_n + 2^{-(n+1)})] \right\} \\ &= 2^n \{f(Y_n + 2^{-n}) - f(Y_n)\} = X_n. \quad \square \end{aligned}$$

注意, $X_n = \frac{f(Y_n + 2^{-n}) - f(Y_n)}{2^{-n}}$ 近似等于 f 对 Z 的随机导数.

以上列举了十个鞅的例子, 许多时候用鞅可以解决原来不易解决的问题. 但关键是如何构造出鞅来.

§ 4.2 上鞅 (下鞅) 及分解定理

定义 设 $\{X_n, n \geq 0\}$ 与 $\{Y_n, n \geq 0\}$ 是随机过程, 称 $\{X_n, n \geq 0\}$ 关于 $\{Y_n, n \geq 0\}$ 是一个 **上鞅**, 如果

1° $E(X_n^-) > -\infty$, 其中 $x^- = \min(x, 0)$;

2° $E(X_{n+1} | Y_0, Y_1, \dots, Y_n) \leq X_n$;

3° X_n 是 Y_0, Y_1, \dots, Y_n 的函数. □

定义 设 $\{X_n, n \geq 0\}$ 与 $\{Y_n, n \geq 0\}$ 是随机过程, 称 $\{X_n, n \geq 0\}$ 关于 $\{Y_n, n \geq 0\}$ 是一个 **下鞅**, 如果

1° $E(X_n^+) < \infty$, 其中 $x^+ = \max(x, 0)$;

2° $E(X_{n+1} | Y_0, Y_1, \dots, Y_n) \geq X_n$;

3° X_n 是 Y_0, Y_1, \dots, Y_n 的函数. □

注意, 若 $\{X_n, n \geq 0\}$ 关于 $\{Y_n, n \geq 0\}$ 是上鞅 $\Leftrightarrow \{-X_n, n \geq 0\}$ 关于 $\{Y_n, n \geq 0\}$ 是下鞅.

上 (下) 鞅可用不公平赌博来解释.

例 1 设 $\{Y_n, n \geq 0\}$ 是马氏链, $P = (p_{ij})$, f 是 P 的有界右超正则函数, 即

$$\sum_{j \in S} p_{ij} f(j) \leq f(i) \text{ 且 } |f(i)| \leq M.$$

若令 $X_n = f(Y_n)$, 则 $\{X_n, n \geq 0\}$ 关于 $\{Y_n, n \geq 0\}$ 是上鞅.

证: 按定义验证, 显然 1°, 3° 成立, 只需证明 2° 成立即可.

我们有

$$E(X_{n+1} | Y_0, Y_1, \dots, Y_n) = E(f(Y_{n+1}) | Y_n) = \sum_{j \in S} f(j) p_{Y_n j} \leq f(Y_n) = X_n. \quad \square$$

为后面讲述方便, 先介绍一下 Jensen 不等式.

设 $\phi(x)$ 为凸函数, 即 $\forall x_1, x_2 \in R, 0 < \alpha < 1$, 有

$$\alpha \phi(x_1) + (1 - \alpha) \phi(x_2) \geq \phi(\alpha x_1 + (1 - \alpha) x_2).$$

将其推广, 设 $x_i (i = 1, 2, \dots, m) \in R, 0 \leq \alpha_i \leq 1, \sum_{i=1}^m \alpha_i = 1$. 则

$$\sum_{i=1}^m \alpha_i \phi(x_i) \geq \phi\left(\sum_{i=1}^m \alpha_i x_i\right),$$

因此

$$E(\phi(X)) \geq \phi(E(X)).$$

故, 当 ϕ 是凸函数时, 有

$$E[\phi(X) | Y_0, Y_1, \dots, Y_n] \geq \phi(E(X | Y_0, Y_1, \dots, Y_n)).$$

引理 1 如 $\{X_n, n \geq 0\}$ 关于 $\{Y_n, n \geq 0\}$ 是鞅, ϕ 是凸函数, 且 $\forall n, E(\phi(X_n)^+) < \infty$, 则 $\{\phi(X_n), n \geq 0\}$ 是关于 $\{Y_n, n \geq 0\}$ 的一个下鞅. \square

推论: 如 $\{X_n, n \geq 0\}$ 关于 $\{Y_n, n \geq 0\}$ 是鞅, $E(X_n^2) < \infty$, 则 $\{|X_n|, n \geq 0\}$ 与 $\{X_n^2, n \geq 0\}$ 关于 $\{Y_n, n \geq 0\}$ 是下鞅. \square

上(下)鞅有以下基本性质:

1° 如 $\{X_n, n \geq 0\}$ 是关于 $\{Y_n, n \geq 0\}$ 的(上)鞅, 则

$$E(X_{n+k} | Y_0, Y_1, \dots, Y_n)(\leq) = X_n, \quad \forall k \geq 0. \quad (4.2.1)$$

证: 用数学归纳法证之. 仅证上鞅时的情形, 当为鞅时, 将“ \leq ”改成“ $=$ ”即可.

当 $k=1$ 时, 由定义, (4.2.1) 式成立.

设 $E(X_{n+k} | Y_0, Y_1, \dots, Y_n) \leq X_n$ 成立, 要证明 $E(X_{n+k+1} | Y_0, Y_1, \dots, Y_n) \leq X_n$ 也成立. 因为

$$\begin{aligned} E(X_{n+k+1} | Y_0, Y_1, \dots, Y_n) &= E\{E(X_{n+k+1} | Y_0, Y_1, \dots, Y_{n+k}) | Y_0, Y_1, \dots, Y_n\} \\ &\leq E(X_{n+k} | Y_0, Y_1, \dots, Y_n) \leq X_n, \end{aligned}$$

因此对所有 $k \geq 0$, (4.2.1) 式成立. \square

2° 若 $\{X_n, n \geq 0\}$ 是(上)鞅, 则对 $0 \leq k \leq n$, 有

$$E(X_n)(\leq) = E(X_k)(\leq) = E(X_0).$$

证: 利用 (4.2.1) 有 $E\{X_n | Y_0, \dots, Y_k\}(\leq) = X_k$, 故

$$E(X_n) = E\{E[X_n | Y_0, \dots, Y_k]\}(\leq) = E(X_k).$$

类似地可证 $E(X_k)(\leq) = E(X_0)$. \square

3° 如 $\{X_n, n \geq 0\}$ 关于 $\{Y_n, n \geq 0\}$ 是(上)鞅, g 是关于 Y_0, Y_1, \dots, Y_n 的(非负)函数, 则

$$E\{g(Y_0, Y_1, Y_n) \cdot X_{n+k} | Y_0, Y_1, \dots, Y_n\}(\leq) = g(Y_0, Y_1, \dots, Y_n)X_n, \quad \forall k \geq 0.$$

证: 因为 g 是关于 Y_0, Y_1, \dots, Y_n 的(非负)函数, 因此

$$\begin{aligned} E(g(Y_0, Y_1, \dots, Y_n)X_{n+k} | Y_0, Y_1, \dots, Y_n) &= g(Y_0, Y_1, \dots, Y_n) \cdot E(X_{n+k} | Y_0, Y_1, \dots, Y_n) \\ &(\leq) = g(Y_0, Y_1, \dots, Y_n)X_n. \quad \square \end{aligned}$$

上一节讨论了许多鞅的例子, 在实际中常常把上鞅和下鞅分解成鞅来处理.

对于上鞅和下鞅, 有一分解定理, 它是鞅论中的基本定理之一.

定理 4.2.1 对于任意一个 $\{X_n, n \geq 1\}$ 关于 $\{Y_n, n \geq 1\}$ 的下鞅, 必存在过程 $\{M_n, n \geq 1\}$ 与 $\{Z_n, n \geq 1\}$, 使得

4.2 上鞅 (下鞅) 及分解定理

- 1° $\{M_n, n \geq 1\}$ 关于 $\{Y_n, n \geq 1\}$ 是鞅;
 2° Z_n 是 Y_1, \dots, Y_{n-1} 的函数 ($n \geq 2$), 且 $Z_1 = 0, Z_n \leq Z_{n+1}, EZ_n < +\infty$;
 3° $X_n = M_n + Z_n (n \geq 1)$.

且上述分解是唯一的.

证: 先证存在性. 令 $Z_1 = 0, M_0 = X_0$, 及

$$M_n = X_n - \sum_{k=1}^n E(X_k - X_{k-1} | Y_1, \dots, Y_{k-1}), \quad n \geq 1,$$

$$Z_n = X_n - M_n = \sum_{k=1}^n E(X_k - X_{k-1} | Y_1, \dots, Y_{k-1}), \quad n \geq 2.$$

因为 $\{X_n, n \geq 1\}$ 关于 $\{Y_n, n \geq 1\}$ 是下鞅, 因此

$$E(X_k | Y_1, \dots, Y_{k-1}) \geq X_{k-1}, \quad E(X_{k-1} | Y_1, \dots, Y_{k-1}) = X_{k-1},$$

进而有

$$E(X_k - X_{k-1} | Y_1, \dots, Y_{k-1}) \geq 0.$$

因此 Z_n 非负且单调非降, 且 Z_n 是 Y_1, \dots, Y_{n-1} 的函数. 同时由 Z_n 的定义有

$$E|Z_n| \leq E|X_n| + E|X_1| < +\infty.$$

另外

$$\begin{aligned} & E(M_n | Y_1, \dots, Y_{n-1}) \\ &= E \left\{ \left[X_n - \sum_{k=1}^n E(X_k - X_{k-1} | Y_1, \dots, Y_{k-1}) \right] \middle| Y_1, \dots, Y_{n-1} \right\} \\ &= E(X_n | Y_1, \dots, Y_{n-1}) - \sum_{k=1}^n E \left(E(X_k - X_{k-1} | Y_1, \dots, Y_{k-1}) \middle| Y_1, \dots, Y_{n-1} \right) \\ &= E(X_n | Y_1, \dots, Y_{n-1}) - \sum_{k=1}^n E(X_k - X_{k-1} | Y_1, \dots, Y_{k-1}) \\ &= E(X_n | Y_1, \dots, Y_{n-1}) - \sum_{k=1}^{n-1} E(X_k - X_{k-1} | Y_1, \dots, Y_{k-1}) - E(X_n - X_{n-1} | Y_1, \dots, Y_{n-1}) \\ &= X_{n-1} - \sum_{k=1}^{n-1} E(X_k - X_{k-1} | Y_1, \dots, Y_{k-1}) = M_{n-1}, \end{aligned}$$

又

$$E|M_n| = E|X_n - Z_n| \leq E|X_n| + E|Z_n| < \infty.$$

因此 $\{M_n, n \geq 1\}$ 关于 $\{Y_n, n \geq 1\}$ 是鞅, 且 $X_n = M_n + Z_n$. 故存在性得证.

下面证唯一性. 设另一分解 M'_n, Z'_n 满足上面定理要求, 即

$$X_n = M'_n + Z'_n, \quad n \geq 1, \quad Z'_1 = 0, \quad M'_0 = X_0 = 0.$$

则

$$M_n + Z_n = M'_n + Z'_n = X_n.$$

令 $\Delta_n = M_n - M'_n = Z'_n - Z_n$. 因为 $\{M_n, n \geq 1\}$ 和 $\{M'_n, n \geq 1\}$ 均是关于 $\{Y_n, n \geq 1\}$ 的鞅, 因此 $\{\Delta_n, n \geq 1\}$ 也是关于 $\{Y_n, n \geq 1\}$ 的鞅. 所以有

$$E(\Delta_n | Y_1, \dots, Y_{n-1}) = \Delta_{n-1}.$$

又因为 Z_n, Z'_n 是关于 Y_1, \dots, Y_{n-1} 的函数. 因此 Δ_n 也是关于 Y_1, \dots, Y_{n-1} 的函数, 于是

$$E(\Delta_n | Y_1, \dots, Y_{n-1}) = \Delta_n,$$

进而

$$\Delta_n = \Delta_{n-1} = \Delta_{n-2} = \dots = \Delta_1 = Z'_1 - Z_1 = 0.$$

故

$$Z_n = Z'_n, M_n = M'_n. \quad \square$$

由本定理可知, 一个下鞅总可分解为一个鞅与一增过程之和.

推论: 若 $\{X_n, n \geq 1\}$ 关于 $\{Y_n, n \geq 1\}$ 是上鞅, 则可分解为 $X_n = M_n - Z_n$ 使得

1° $\{M_n, n \geq 1\}$ 关于 $\{Y_n, n \geq 1\}$ 是鞅;

2° Z_n 是 Y_1, \dots, Y_{n-1} 的函数 ($n \geq 2$), $Z_1 = 0, Z_n \leq Z_{n+1}, EZ_n < +\infty$.

且上述分解是唯一的. □

例 1 鞅在序贯决策模型中的应用

考虑一个可控的随机动态系统, 状态空间有限, 记为 $S = \{1, 2, \dots, p\}$. 行动集 $A = \{a, b, \dots, l\}$ 有限, 有时称 A 为 **决策空间**. 设我们每经单位时间 (如每小时, 每天, 每月等) 观察即时的系统状态 i , 然后从 A 中选取一个行动 a , 有两件事情发生:

(I) 得到一个报酬 (或能量) $r(i, a)$;

(II) 在现时段状态为 i , 采取行动为 a 的条件下, 系统下一时刻转移到状态 j 的概率为 $q(j|i, a)$.

我们的问题是: 在每一时刻如何选取行动, 使前 N 时段的期望总报酬 (总能量) 达到最大?

令 Δ_k 表 k 时段采取的行动; Y_k 表 k 时段系统的状态; $h_{n-1} = \{i_0, a_0, i_1, a_1, \dots, i_{n-1}, a_{n-1}\}$ 表示 $n-1$ 时刻及以前系统的状态及采取行动的交互序列, 称为 $n-1$ 之前的历史. 设 n 时刻采取的行动 (决策) a_n 依赖于 h_{n-1} 与 i_n , 记为

$$a_n = \pi_n(h_{n-1}, i_n) = \pi_n(i_0, a_0, i_1, a_1, \dots, i_{n-1}, a_{n-1}, i_n),$$

4.2 上鞅 (下鞅) 及分解定理

其中 π_n 称为 n 时刻的决策函数.

一个策略 $\pi = \{\pi_0, \pi_1, \dots, \pi_{N-1}\}$ 是一个决策函数序列. 若给定一个策略 π 及初始状态 $Y_0 = i$, 则直到 $N-1$ 时刻的期望总报酬为

$$V(\pi, i) = E_\pi \left\{ \sum_{k=0}^{N-1} r(Y_k, \Delta_k) \mid Y_0 = i \right\}.$$

式中 E_π 表示在 π 的条件下求期望. 我们的目的是选取一最优策略 π^* , 使对所有 $i \in S$, 有

$$V(\pi^*, i) = \max_{\pi} V(\pi, i). \quad (4.2.2)$$

为此, 记 $V_N(i) = 0, \forall i \in S$. $V_k(i), i \in S$, 满足

$$V_{k-1}(i) = \max_{a \in A} \left\{ r(i, a) + \sum_{j \in S} q(j \mid i, a) V_k(j) \right\}, \quad 1 \leq k \leq N. \quad (4.2.3)$$

令

$$X_n = \sum_{k=1}^n \left\{ V_k(Y_k) - E[V_k(Y_k) \mid Y_0, \Delta_0, Y_1, \Delta_1, \dots, Y_{k-1}, \Delta_{k-1}] \right\}.$$

由 § 4.1 例 3 可知, $\{X_n, n \geq 1\}$ 关于 $\{(Y_n, \Delta_n), n \geq 0\}$ 是鞅, 于是

$$EX_n = EX_1 = 0. \quad (4.2.4)$$

由 (4.2.3) 式有

$$V_{k-1}(i) \geq r(i, a) + \sum_{j \in S} q(j \mid i, a) V_k(j), \quad \forall i \in S, a \in A.$$

故

$$\begin{aligned} V_{k-1}(Y_{k-1}) &\geq r(Y_{k-1}, \Delta_{k-1}) + \sum_{j \in S} q(j \mid Y_{k-1}, \Delta_{k-1}) V_k(j) \\ &= r(Y_{k-1}, \Delta_{k-1}) + E\{V_k(Y_k) \mid Y_{k-1}, \Delta_{k-1}\} \end{aligned}$$

因此由马氏性得

$$V_{k-1}(Y_{k-1}) \geq r(Y_{k-1}, \Delta_{k-1}) + E\{V_k(Y_k) \mid Y_0, \Delta_0, Y_1, \Delta_1, \dots, Y_{k-1}, \Delta_{k-1}\}. \quad (4.2.5)$$

于是有

$$\begin{aligned} 0 = EX_N &= E \left\{ \sum_{k=1}^N [V_k(Y_k) - E(V_k(Y_k) \mid Y_0, \Delta_0, \dots, Y_{k-1}, \Delta_{k-1})] \right\} \\ &\geq E \left\{ \sum_{k=1}^N [V_k(Y_k) + r(Y_{k-1}, \Delta_{k-1}) - V_{k-1}(Y_{k-1})] \right\} \\ &= E \left\{ \sum_{k=0}^{N-1} r(Y_k, \Delta_k) + V_N(Y_N) - V_0(Y_0) \right\}. \end{aligned}$$

即

$$E(V_0(Y_0)) \geq E_\pi \left\{ \sum_{k=0}^{N-1} r(Y_k, \Delta_k) \middle| Y_0 \right\}.$$

若 $Y_0 = i$, 则上式说明, 对任意 π , 有

$$V_0(i) \geq E_\pi \left\{ \sum_{k=0}^{N-1} r(Y_k, \Delta_k) \middle| Y_0 = i \right\}.$$

即 $V_0(i) \geq V(\pi, i)$ 对 $\forall i \in S$ 及所有 π 均成立.

如我们选取 $a_{k-1}^* \in A$, 使 $a_{k-1}^*(i) = \pi_{k-1}^*(i_0, a_0^*, \dots, i_{k-1})$ 满足 (4.2.3) 式, 即

$$\begin{aligned} V_{k-1}(i) &= r(i, a_{k-1}^*(i)) + \sum_{j \in S} q(j|i, a_{k-1}^*(i)) V_k(j) \\ &= \max_a \left\{ r(i, a) + \sum_j q(j|i, a) V_k(j) \right\}, \quad \forall i \in S. \end{aligned}$$

则 $\pi^* = \{\pi_0^*, \pi_1^*, \dots, \pi_{N-1}^*\}$ 是最优策略, 即

$$V_0(i) = V(\pi^*, i), \quad \forall i \in S.$$

换言之, 我们是通过使每一步均取最优来达到总体最优的. □

从上面的例子可以得到鞅应用的感性认识. 利用鞅的性质可以解决许多本来不易研究的问题, 但关键是怎样构造出一个合适的鞅来. 这通常也不是件容易的事, 需要经验, 也需要技巧.

§ 4.3 停时与停时定理

本节要研究当 T 是一随机变量时, EX_T 是否等于 EX_0 . 为此引出停时的概念. 停时是一个不依赖于“将来”的随机时间. 先给出粗略的直观定义.

定义 设取值为非负整数 (包括 $+\infty$) 的随机变量 T , 及随机序列 $\{Y_n, n \geq 0\}$. 若对 $n \geq 0$, 事件 $\{T = n\}$ 的示性函数 $I_{\{T=n\}}$ 仅是 Y_0, Y_1, \dots, Y_n 的函数, 则称 T 是关于 $\{Y_n, n \geq 0\}$ 的 **停时**(stopping time)(或称马氏时间). □

为今后叙述方便, 引入一些记号, 记 $\sigma(X)$ 为由 r.v. X 决定的事件及它们的有限和可列运算的全体构成的事件集. 简称为由 X 生成的事件 σ 域, 它表示由 r.v. X 可能提供的全部信息. 同样, 记 $\sigma(Y_0, Y_1, \dots, Y_n) = \sigma(Y_k, 0 \leq k \leq n)$, 称之为由 r.v. 序列 Y_0, Y_1, \dots, Y_n 生成的事件 σ 域. 它表示由 Y_0, Y_1, \dots, Y_n 可能提供的全部信息. 例如, 在样本空间 Ω 中定义的事件 A 及 B 的示性函数 I_A 及 I_B , 那么

$$\sigma(I_A) = \{\emptyset, A, A^C, \Omega\}, \quad \sigma(I_B) = \{\emptyset, B, B^C, \Omega\},$$

4.3 停时与停时定理

$$\sigma(I_A, I_B) = \{\emptyset, A, B, A^C, B^C, A-B, B-A, AB, A \cup B, (A-B)^C, (B-A)^C, (AB)^C, (A \cup B)^C, (A-B) \cup (B-A), [(A-B) \cup (B-A)]^C, \Omega\}.$$

通常简记

$$\mathcal{F}_n = \sigma(Y_k, 0 \leq k \leq n) = \sigma(Y_0, Y_1, \dots, Y_n), \quad n \geq 0.$$

若 $\forall n \geq 0, \{T = n\} \in \mathcal{F}_n$, 则 $\{T = n\}$ 与 $\{T \neq n\}$ 完全取决于过程直到 n 时刻的信息 (Y_0, Y_1, \dots, Y_n) , 而与过程的未来无关.

由定义知, 若 $\forall n \geq 0$, 事件 $\{T \leq n\}, \{T > n\}, \{T \geq n\}, \{T < n\}$ 均只由 (Y_0, Y_1, \dots, Y_n) 确定, 则 T 是一停时.

因此, 下面给出停时的确切定义如下:

定义 设有非负整数的随机变量 T , 及随机序列 $\{Y_n, n \geq 0\}$, $\mathcal{F}_n = \sigma(Y_k, 0 \leq k \leq n)$. 若对 $\forall n \geq 0, \{T = n\} \in \mathcal{F}_n$, 称则 T 是 $\{Y_n, n \geq 0\}$ 的停时. \square

对随机过程 $\{Y_n, n \geq 0\}$, 令 $T = \min\{n : Y_n \in A\}$, 即 T 是首次达 A 的时间. 则 T 是关于 $\{Y_n, n \geq 0\}$ 的停时. 因为 $\{T > n\} = \{\omega : Y_k \notin A, \forall k \leq n\} \in \mathcal{F}_n$. 即事件 $\{T > n\}$ 发生与否完全由 (Y_0, Y_1, \dots, Y_n) 确定.

例: $\{N(t), t \geq 0\}$ 是参数为 λ 的时齐 Poisson 过程, $S_0 = 0, S_n$ 为第 n 个事件发生时刻, 则 $N(t)$ 关于 $\{S_n, n \geq 0\}$ 不是停时, 但 $N(t) + 1$ 关于 $\{S_n, n \geq 0\}$ 是停时.

显然 $T = k$ (k 是一常数) 是一个停时.

停时有以下基本特性:

设 T, σ 是关于 $\{Y_n, n \geq 0\}$ 的两个停时, 则 $T + \sigma, T \wedge \sigma = \min(T, \sigma), T \vee \sigma = \max(T, \sigma)$ 均是停时.

下面介绍有关停时定理 (Optional stopping theorem 或 Optional Sampling theorem).

为此, 先介绍以下几个引理.

引理 4.3.1 设 $\{X_n, n \geq 0\}$ 是一关于 $\{Y_n, n \geq 0\}$ 的 (上) 鞅, T 是一关于 $\{Y_n, n \geq 0\}$ 的停时, 则 $\forall n \geq k$ 有

$$E(X_n \cdot I_{(T=k)}) (\leq) = E(X_k \cdot I_{(T=k)}).$$

证: 注意到 T 是关于 $\{Y_n, n \geq 0\}$ 的停时, 则 $\{T = k\}$ 仅与 Y_0, Y_1, \dots, Y_k 有关, 所以 $I_{(T=k)}$ 是关于 Y_0, Y_1, \dots, Y_k 的函数. 因此

$$\begin{aligned} E(X_n \cdot I_{(T=k)}) &= E(E(X_n \cdot I_{(T=k)}) | Y_0, Y_1, \dots, Y_k) \\ &= E(I_{(T=k)} \cdot E(X_n | Y_0, Y_1, \dots, Y_k)) (\leq) = E(I_{(T=k)} \cdot X_k). \quad \square \end{aligned}$$

引理 4.3.2 如 $\{X_n, n \geq 0\}$ 关于 $\{Y_n, n \geq 0\}$ 是 (上) 鞅, T 关于 $\{Y_n, n \geq 0\}$ 是停时, 则 $\forall n \geq 1$, 有

$$EX_0(\geq) = EX_{T \wedge n}(\geq) = EX_n.$$

证：注意到 $I_{\{T < n\}} + I_{\{T \geq n\}} = 1$, 并利用引理 4.3.1 得

$$\begin{aligned}
 EX_{T \wedge n} &= E \left\{ X_{T \wedge n} \left(\sum_{k=0}^{n-1} I_{\{T=k\}} + I_{\{T \geq n\}} \right) \right\} \\
 &= E \left\{ X_{T \wedge n} \cdot \sum_{k=0}^{n-1} I_{\{T=k\}} \right\} + E \{ X_{T \wedge n} \cdot I_{\{T \geq n\}} \} \\
 &= \sum_{k=0}^{n-1} E \{ X_{T \wedge n} \cdot I_{\{T=k\}} \} + E \{ X_{T \wedge n} \cdot I_{\{T \geq n\}} \} \\
 &= \sum_{k=0}^{n-1} E \{ X_k \cdot I_{\{T=k\}} \} + E \{ X_n \cdot I_{\{T \geq n\}} \} \\
 (\geq) &= \sum_{k=0}^{n-1} E \{ X_n \cdot I_{\{T=k\}} \} + E \{ X_n \cdot I_{\{T \geq n\}} \} = EX_n \cdot \sum_{k=0}^{\infty} I_{\{T=k\}} = EX_n.
 \end{aligned}$$

因此

$$EX_{T \wedge n}(\geq) = EX_n.$$

对于鞅, 因为 $EX_n = EX_0$, 所以 $EX_{T \wedge n} = EX_0$.

对于上鞅, 下面证明 $EX_0 \geq EX_{T \wedge n}$. 设

$$\begin{aligned}
 \tilde{X}_0 &= 0, \\
 \tilde{X}_n &= \sum_{k=1}^n [X_k - E(X_k | Y_0, Y_1, \dots, Y_{k-1})], \quad n \geq 1.
 \end{aligned}$$

根据 § 4.1 例 3 可知, $\{\tilde{X}_n, n \geq 0\}$ 关于 $\{Y_n, n \geq 0\}$ 是鞅. 由鞅的性质可知

$$E\tilde{X}_n = E\tilde{X}_{T \wedge n} = E\tilde{X}_0 = 0,$$

因此有

$$\begin{aligned}
 0 &= E\tilde{X}_{T \wedge n} = E \left[\sum_{k=1}^{T \wedge n} (X_k - E(X_k | Y_0, Y_1, \dots, Y_{k-1})) \right] \\
 &\geq E \left[\sum_{k=1}^{T \wedge n} (X_k - X_{k-1}) \right] \quad (\text{由上鞅定义得}) \\
 &= E(X_{T \wedge n} - X_0) = E(X_{T \wedge n}) - E(X_0).
 \end{aligned}$$

因此

$$EX_{T \wedge n} \leq EX_0. \quad \square$$

引理 4.3.3 设 X 是一随机变量, 满足 $E|X| < \infty$. T 是关于 $\{Y_n, n \geq 0\}$ 的停时, 且 $P(T < \infty) = 1$, 则

$$\begin{aligned}
 \lim_{n \rightarrow \infty} E(X \cdot I_{\{T > n\}}) &= 0, \\
 \lim_{n \rightarrow \infty} E(X \cdot I_{\{T \leq n\}}) &= EX.
 \end{aligned}$$

4.3 停时与停时定理

证: 因为

$$|X| = |X|I_{\{T \leq n\}} + |X|I_{\{T > n\}} \geq |X|I_{\{T \leq n\}},$$

并且

$$\lim_{n \rightarrow \infty} I_{\{T \leq n\}} = \lim_{n \rightarrow \infty} \sum_{k=1}^n I_{\{T=k\}} = \sum_{k=1}^{\infty} I_{\{T=k\}} = 1.$$

因此

$$E|X| \geq E(|X|I_{\{T \leq n\}}) \xrightarrow{(n \rightarrow \infty)} \sum_{k=0}^{\infty} E\{|X|I_{\{T=k\}}\} = E|X|.$$

于是有

$$\lim_{n \rightarrow \infty} E(|X|I_{\{T \leq n\}}) = E|X|, \quad \lim_{n \rightarrow \infty} E(|X| \cdot I_{\{T > n\}}) = 0.$$

由上式知

$$\lim_{n \rightarrow \infty} E(X \cdot I_{\{T > n\}}) = 0.$$

又因为

$$|E(X \cdot I_{\{T \leq n\}}) - EX| = |EX \cdot I_{\{T > n\}}| \leq E|X \cdot I_{\{T > n\}}| = E(|X|I_{\{T > n\}}) \xrightarrow{(n \rightarrow \infty)} 0.$$

即

$$\lim_{n \rightarrow \infty} E(X \cdot I_{\{T \leq n\}}) = EX. \quad \square$$

定理 4.3.1 设 $\{X_n, n \geq 0\}$ 是鞅, T 是停时, 若 $P(T < \infty) = 1$, 且

$$E(\sup_{n \geq 0} |X_{T \wedge n}|) < \infty,$$

则

$$EX_T = EX_0.$$

证: 记 $Z = \sup_{n \geq 0} |X_{T \wedge n}|$. 因为

$$X_T = \sum_{k=0}^{\infty} (X_k \cdot I_{\{T=k\}}) = \sum_{k=0}^{\infty} (X_{T \wedge k} \cdot I_{\{T=k\}}).$$

因此

$$\begin{aligned} |X_T| &= \left| \sum_{k=0}^{\infty} (X_{T \wedge k} \cdot I_{\{T=k\}}) \right| \leq \sum_{k=0}^{\infty} (|X_{T \wedge k}| \cdot I_{\{T=k\}}) \\ &\leq \sup_{n \geq 0} |X_{T \wedge n}| \cdot \sum_{k=0}^{\infty} I_{\{T=k\}} = \sup_{n \geq 0} |X_{T \wedge n}| = Z. \end{aligned}$$

所以有

$$E|X_T| \leq E(Z) < \infty.$$

即 EX_T 有意义.

又

$$\begin{aligned} |EX_{T \wedge n} - EX_T| &= |E[(X_{T \wedge n} - X_T) \cdot I_{\{T > n\}}] + E[(X_{T \wedge n} - X_T) \cdot I_{\{T \leq n\}}]| \\ &= |E(X_{T \wedge n} - X_T) \cdot I_{\{T > n\}}| \leq E|(X_{T \wedge n} - X_T) \cdot I_{\{T > n\}}| \\ &\leq E|(X_{T \wedge n} \cdot I_{\{T > n\}}| + E|X_T \cdot I_{\{T > n\}}| \leq 2E(Z \cdot I_{\{T > n\}}). \end{aligned}$$

由引理 4.3.3 知 $\lim_{n \rightarrow \infty} E(Z \cdot I_{\{T > n\}}) = 0$. 因此

$$\lim_{n \rightarrow \infty} EX_{T \wedge n} = EX_T.$$

又由引理 4.3.2 得 $EX_{T \wedge n} = EX$. 所以

$$EX_T = \lim_{n \rightarrow \infty} EX_{T \wedge n} = \lim_{n \rightarrow \infty} EX_0 = EX_0. \quad \square$$

推论: 设 $\{X_n, n \geq 0\}$ 是鞅, T 是停时, 且 $ET < \infty$. 若存在一常数 $b < \infty$, 满足对 $\forall n < T$, 有

$$E(|X_{n+1} - X_n| | Y_0, Y_1, \dots, Y_n) \leq b,$$

则

$$EX_0 = EX_T.$$

证: 令

$$\begin{aligned} Z_0 &= |X_0|, \\ Z_n &= |X_n - X_{n-1}|, \quad n \geq 1, \\ W &= Z_0 + Z_1 + \dots + Z_T. \end{aligned}$$

则

$$\begin{aligned} W &= |X_0| + |X_1 - X_0| + \dots + |X_T - X_{T-1}|, \\ EW &= \sum_{n=0}^{\infty} \sum_{k=0}^n E(Z_k I_{\{T=n\}}) = \sum_{k=0}^{\infty} \sum_{n=k}^{\infty} E(Z_k I_{\{T=n\}}) = \sum_{k=0}^{\infty} E(Z_k \cdot I_{\{T \geq k\}}). \end{aligned}$$

因为 $I_{\{T \geq k\}} = 1 - I_{\{T \leq k-1\}}$ 仅仅是 Y_0, Y_1, \dots, Y_{k-1} 的函数, 又由已知条件知, 对 $k \leq T$ 有 $E(Z_k | Y_0, \dots, Y_{k-1}) \leq b$. 因此

$$\begin{aligned} \sum_{k=0}^{\infty} E(Z_k \cdot I_{\{T \geq k\}}) &= \sum_{k=0}^{\infty} E\{E(Z_k \cdot I_{\{T \geq k\}} | Y_0, Y_1, \dots, Y_{k-1})\} \\ &= \sum_{k=0}^{\infty} E\{I_{\{T \geq k\}} \cdot E(Z_k | Y_0, Y_1, \dots, Y_{k-1})\} \\ &\leq b \sum_{k=0}^{\infty} P(T \geq k) = b(1 + ET) \quad (\text{利用 } \sum_{k=1}^{\infty} P(T \geq k) = ET) \\ &< \infty. \end{aligned}$$

4.3 停时与停时定理

即 $EW < \infty$. 因为 $|X_T| \leq W$, 因此 $|X_{T \wedge n}| \leq W, \forall n \geq 0$, 即

$$\sup_{n \geq 0} |X_{T \wedge n}| \leq W.$$

所以有

$$E(\sup_{n \geq 0} |X_{T \wedge n}|) \leq EW < \infty.$$

又因为 $ET < \infty$, 因此有

$$P(T < \infty) = 1.$$

利用定理 4.3.1, 即得

$$EX_T = EX_0. \quad \square$$

定理 4.3.2 (停时定理) 设 $\{X_n, n \geq 0\}$ 是鞅, T 是停时, 若

$$1^\circ \quad P(T < \infty) = 1;$$

$$2^\circ \quad E|X_T| < \infty;$$

$$3^\circ \quad \lim_{n \rightarrow \infty} E|X_n \cdot I_{\{T > n\}}| = 0.$$

则

$$EX_T = EX_0.$$

证: 由

$$X_T = X_T I_{\{T \leq n\}} + X_T I_{\{T > n\}},$$

及

$$X_T I_{\{T \leq n\}} = X_{T \wedge n} I_{\{T \leq n\}} = X_{T \wedge n} (1 - I_{\{T > n\}}) = X_{T \wedge n} - X_{T \wedge n} I_{\{T > n\}} = X_{T \wedge n} - X_n I_{\{T > n\}}.$$

得

$$X_T = X_{T \wedge n} - X_n \cdot I_{\{T > n\}} + X_T \cdot I_{\{T > n\}}.$$

因此

$$EX_T = EX_{T \wedge n} - E(X_n \cdot I_{\{T > n\}}) + E(X_T \cdot I_{\{T > n\}}).$$

由已知 $\lim_{n \rightarrow \infty} E|X_n \cdot I_{\{T > n\}}| = 0$, 则

$$\lim_{n \rightarrow \infty} E(X_n \cdot I_{\{T > n\}}) = 0.$$

由引理 4.3.3 得

$$\lim_{n \rightarrow \infty} E(X_T \cdot I_{\{T > n\}}) = 0.$$

因此

$$\lim_{n \rightarrow \infty} EX_{T \wedge n} = EX_T.$$

而由引理 4.3.2 知 $EX_{T \wedge n} = EX_0$. 故

$$EX_0 = EX_T. \quad \square$$

这个基本定理有以下简单推论.

推论 1 设 $\{X_n, n \geq 0\}$ 是鞅, T 是停时, 若

1° $P(T < \infty) = 1$;

2° 对某个 $k < \infty, \forall n \geq 0, E(X_{T \wedge n}^2) \leq k$.

则

$$EX_0 = EX_T.$$

证: 显然 $X_{T \wedge n}^2 \geq 0$. 由 2° 知

$$E(X_{T \wedge n}^2 I_{\{T \leq n\}}) \leq E(X_{T \wedge n}^2) \leq k.$$

而

$$\begin{aligned} E(X_{T \wedge n}^2 I_{\{T \leq n\}}) &= \sum_{k=0}^n E[X_T^2 | T = k] \cdot P(T = k) \\ &\xrightarrow{(n \rightarrow \infty)} \sum_{k=0}^{\infty} E(X_T^2 | T = k) \cdot P(T = k) = EX_T^2, \end{aligned}$$

因此

$$EX_T^2 \leq k < \infty.$$

由 Schwartz 不等式可得

$$E|X_T| = E|X_T \cdot 1| \leq [E(X_T^2)]^{\frac{1}{2}} < \infty,$$

及

$$(E(X_n I_{\{T > n\}}))^2 = [E(X_{T \wedge n} \cdot I_{\{T > n\}})]^2 \leq E(X_{T \wedge n}^2) \cdot E(I_{\{T > n\}}^2),$$

即

$$(E(X_n \cdot I_{\{T > n\}}))^2 \leq k \cdot P\{T > n\} \xrightarrow{(n \rightarrow \infty)} 0.$$

因此

$$\lim_{n \rightarrow \infty} E[X_n \cdot I_{\{T > n\}}] = 0.$$

利用定理 4.3.2 得

$$EX_0 = EX_T. \quad \square$$

推论 2 设 $Y_0 = 0, \{Y_k, k \geq 1\}$ 独立同分布, $EY_k = \mu, DY_k = \sigma^2 < \infty, S_0 = 0, S_n = \sum_{k=1}^n Y_k, X_n = S_n - n\mu$. 若 T 为停时, $ET < \infty$, 则

$$E|X_T| < \infty,$$

4.3 停时与停时定理

且

$$EX_T = ES_T - \mu ET = 0.$$

证：因为 $ET = \sum_{k=0}^{\infty} kP(T = k) < +\infty$, 从而余项

$$\sum_{k=n}^{\infty} kP(T = k) \rightarrow 0, \quad (n \rightarrow \infty),$$

又

$$\sum_{k=n}^{\infty} kP(T = k) \geq \sum_{k=n}^{\infty} nP(T = k) = nP(T \geq n) \rightarrow 0,$$

故 $nP(T \geq n) \rightarrow 0, (n \rightarrow \infty)$. 因此

$$P(T \geq n) \rightarrow 0, \quad (n \rightarrow \infty).$$

从而

$$P(T < \infty) = 1.$$

$$E|X_T| = E|S_T - T\mu| \leq E\left(\sum_{k=1}^T |Y_k - \mu|\right)$$

因为 $\{Y_k\}$ 独立同分布, 所以 $\{|Y_k - \mu|\}$ 独立同分布, 所以

$$E\left(\sum_{k=1}^T |Y_k - \mu|\right) = ET \cdot E|Y_1 - \mu| < \infty$$

于是

$$E|X_T| < +\infty.$$

由 Schwartz 不等式得

$$[E(X_n I_{\{T > n\}})]^2 \leq EX_n^2 \cdot E(I_{\{T > n\}}) \leq n\sigma^2 P(T \geq n) = \sigma^2(n \cdot P(T \geq n)).$$

由前面的证明过程的中间结论 $nP(T \geq n) \rightarrow 0, (n \rightarrow \infty)$ 知

$$\lim_{n \rightarrow \infty} E(X_n \cdot I_{\{T > n\}}) = 0.$$

利用定理 4.3.2 得

$$0 = EX_0 = EX_T = ES_T - \mu ET. \quad \square$$

127

如何在实际中应用停时定理与推论呢? 这里介绍一个应用停时定理的例子.

例 1 随机游动

令 $Y_0 = 0, \{Y_k, k \geq 1\}$ 独立同分布, $P(Y_k = 1) = p \geq 0, P(Y_k = -1) = q = 1 - p \geq 0$.
令 $X_0 = 0, X_n = \sum_{k=1}^n Y_k$, 记

$$T_{0j} = \min\{n : X_0 = 0, X_n = j\},$$

$$T = \min\{n : X_n = a \text{ 或 } X_n = b\}, b > 0 \text{ 为正整数}, a < 0 \text{ 为负整数},$$

$${}_bT_a = \min\{n : X_0 = 0, X_l \neq b, 1 \leq l \leq n-1, X_n = a\},$$

$$V_a = P({}_bT_a < \infty | X_0 = 0), V_a \text{ 表从 } 0 \text{ 出发先到达 } a \text{ 的概率}.$$

则 $P({}_aT_b < \infty | X_0 = 0) = 1 - V_a$.

若以赌博 (或投资) 为背景. 设甲乙两人赌博, $|a|$ 表甲原有的资金, Y_n 表甲第 n 次得到的钱, b 表乙原有的资金. 那么 V_a 表示甲先输光的概率.

分二种情况讨论

1° 当 $p = q = \frac{1}{2}$ 时

易证 $P(T_{01} < \infty | X_0 = 0) = 1$ (见第三章练习题). 由 $X_{T_{01}}$ 定义知, $X_{T_{01}} = 1$. 故 $EX_{T_{01}} = 1$, 而 $EX_0 = 0$, 所以 $EX_{T_{01}} \neq EX_0$. 易知 $\{X_n, n \geq 1\}$ 关于 $\{Y_n, n \geq 1\}$ 是鞅, T_{01} 关于 $\{Y_n, n \geq 1\}$ 是停时. 由定理 4.3.1 的推论知, $ET_{01} < \infty$ 不成立 (因为若 $ET_{01} < \infty$, 则 $EX_T = EX_0 = 0$), 故

$$ET_{01} = +\infty.$$

易证 $P(T < \infty | X_0 = 0) = 1$. 而 $|X_{T \wedge n}| \leq \max(|a|, b), \forall n \geq 0$. 因此有

$$E\left(\sup_{n \geq 0} |X_{T \wedge n}|\right) < \infty.$$

由定理 4.3.1 得

$$EX_T = EX_0 = 0.$$

但

$$EX_T = V_a a + (1 - V_a) b = 0,$$

解之, 得

$$V_a = \frac{b}{|a| + b},$$

这就是甲先输光的概率. 同理

$$V_b = 1 - V_a = \frac{|a|}{|a| + b}.$$

128

如何求 $E(T | X_0 = 0)$?, 即任何一方输光的平均时间是多少呢? 这需要构造一个合适的鞅来解决.

4.3 停时与停时定理

设 $Z_n = X_n^2 - n$, 先验证它关于 $\{Y_n, n \geq 0\}$ 是鞅. 因为

$$E|Z_n| = E|X_n^2 - n| \leq EX_n^2 + n < \infty,$$

$$\begin{aligned} E(Z_{n+1} | Y_0, Y_1, \dots, Y_n) &= E(X_{n+1}^2 - n - 1 | Y_0, Y_1, \dots, Y_n) \\ &= E((X_n + Y_{n+1})^2 | Y_0, Y_1, \dots, Y_n) - (n + 1) \\ &= E(X_n^2 | Y_0, \dots, Y_n) + 2E(X_n Y_{n+1} | Y_0, \dots, Y_n) + E(Y_{n+1}^2 | Y_0, \dots, Y_n) - (n + 1) \\ &= X_n^2 + 2X_n \cdot 0 + 1 - (n + 1) = X_n^2 - n = Z_n. \end{aligned}$$

所以 $\{Z_n, n \geq 0\}$ 关于 $\{Y_n, n \geq 0\}$ 是鞅.

由于 T 为停时, 且 $ET < \infty$ (由第三章练习). 另外

$$\begin{aligned} E(|Z_{n+1} - Z_n| | Y_0, \dots, Y_n) &= E(|X_{n+1}^2 - (n + 1) - X_n^2 + n| | Y_0, \dots, Y_n) \\ &= E(|2X_n \cdot Y_{n+1} + Y_{n+1}^2 - 1| | Y_0, \dots, Y_n) \\ &\leq 2E(|X_n \cdot Y_{n+1}| | Y_0, \dots, Y_n) + E(Y_{n+1}^2 | Y_0, \dots, Y_n) + 1 \\ &= 2|X_n| \cdot E|Y_{n+1}| + 1 + 1 \leq 2(\max(|a|, b)) + 2 < \infty. \end{aligned}$$

由定理 4.3.1 的推论知

$$EZ_T = EZ_0 = 0.$$

而由于

$$EZ_T = E(X_T^2 - T) = EX_T^2 - ET,$$

因此

$$ET = EX_T^2 = a^2 V_a + b^2 (1 - V_a) = a^2 \cdot \frac{b}{|a| + b} + b^2 \cdot \frac{|a|}{|a| + b} = |a|b.$$

2° 当 $p - q = \mu > 0$ 时, 这是不公平赌博, 甲方赢的概率大, 这时的 V_a 是多少呢? 为此仍需要构造鞅. 注意到此时 $EY_n = p - q = \mu$. 令 $U_n = X_n - n\mu$.

因为

$$E|U_n| = E|X_n - n\mu| \leq E|X_n| + n\mu \leq n + n\mu < +\infty,$$

$$\begin{aligned} E(U_{n+1} | Y_0, Y_1, \dots, Y_n) &= E(X_{n+1} - (n + 1)\mu | Y_0, Y_1, \dots, Y_n) \\ &= E(X_n + Y_{n+1} | Y_0, Y_1, \dots, Y_n) - (n + 1)\mu \\ &= X_n + \mu - (n + 1)\mu = X_n - n\mu = U_n. \end{aligned}$$

因此 $\{U_n, n \geq 0\}$ 关于 $\{Y_n, n \geq 0\}$ 是鞅.

另外, 由于

$$E(|U_{n+1} - U_n| | Y_0, \dots, Y_n) = E(|Y_{n+1} - \mu| | Y_0, \dots, Y_n) = E|Y_{n+1} - \mu| = 4pq < \infty.$$

因此由定理 4.3.1 的推论知, 在 $ET < \infty$ 的条件下 $EU_T = EU_0$, 故

$$EX_T = \mu ET.$$

令 $V_n = (\frac{q}{p})^{X_n}$, 由于 $p > q$, 故 $0 < \frac{q}{p} < 1$. 下面验证 $\{V_n, n \geq 0\}$ 是鞅.
因为

$$E|V_n| = E|(\frac{q}{p})^{X_n}| = E\{(\frac{q}{p})^{X_n}\} = \prod_{k=1}^n E\{(\frac{q}{p})^{Y_k}\} = 1 < \infty,$$

$$\begin{aligned} E(V_{n+1}|Y_0, \dots, Y_n) &= E\{(\frac{q}{p})^{X_{n+1}}|Y_0, \dots, Y_n\} = E\{(\frac{q}{p})^{X_n} \cdot (\frac{q}{p})^{Y_{n+1}}|Y_0, \dots, Y_n\} \\ &= (\frac{q}{p})^{X_n} \cdot E\{(\frac{q}{p})^{Y_{n+1}}\} = (\frac{q}{p})^{X_n} \cdot [(\frac{q}{p}) \cdot p + (\frac{q}{p})^{-1} \cdot q] = (\frac{q}{p})^{X_n} = V_n. \end{aligned}$$

因此 $\{V_n, n \geq 0\}$ 关于 $\{Y_n, n \geq 0\}$ 是鞅.

由 $a \leq X_n \leq b, 0 < \frac{q}{p} < 1$ 得

$$(\frac{q}{p})^b \leq V_n \leq (\frac{q}{p})^a.$$

因此

$$E|V_T| = E(V_T) \leq (\frac{q}{p})^a < +\infty.$$

故

$$0 \leq \lim_{n \rightarrow \infty} E(V_n I_{\{T > n\}}) \leq \lim_{n \rightarrow \infty} (\frac{q}{p})^a E\{I_{\{T > n\}}\} = (\frac{q}{p})^a \lim_{n \rightarrow \infty} P\{T > n\} = 0.$$

此处 $\lim_{n \rightarrow \infty} P\{T > n\} = 0$ 是因为当 $p - q = \mu > 0$ 时, $[a, b]$ 为马氏链 $\{X_n, n \geq 0\}$ 的非常返状态集. $(X_n = i) \in [a, b]$ 至多有限次, 故有 $P(T < \infty) = 1$, 即 $\lim_{n \rightarrow \infty} P\{T > n\} = 0$. 由此得

$$\lim_{n \rightarrow \infty} E(V_n \cdot I_{\{T > n\}}) = 0.$$

于是由定理 4.3.2 得

$$EV_0 = EV_T.$$

另外, 由于 $EV_0 = E(\frac{q}{p})^{X_0} = 1$, 因此

$$EV_T = 1.$$

同样地记 $V_a = P(bT_a < \infty | X_0 = 0)$, 有

$$EV_T = V_a (\frac{q}{p})^a + (1 - V_a) (\frac{q}{p})^b = 1.$$

解之, 得

$$V_a = \frac{1 - (\frac{q}{p})^b}{(\frac{q}{p})^a - (\frac{q}{p})^b} < \frac{b}{|a| + b}.$$

4.4 鞅收敛定理

故从 0 状态出发, 当 $p > q$ 时先到达 a 的概率小于 $p = q$ 时先到达 a 的概率. \square

§ 4.4 鞅收敛定理

设 $\{X_n, n \geq 0\}$ 关于 $\{Y_n, n \geq 0\}$ 是 (上、下) 鞅. 我们要研究在各种意义下, $\lim_{n \rightarrow \infty} X_n$ 是否存在的问题, 即鞅收敛的问题. 为此, 我们介绍鞅收敛定理, 该定理是利用鞅解决许多不同领域问题的重要工具之一.

在叙述鞅收敛定理之前, 先介绍一个重要引理, 即上穿不等式. 为此, 先考虑实数列 $\{a_n\}$ 的收敛问题. $\{a_n\}$ 没有有穷或无穷极限时的主要条件是 $\liminf_{n \rightarrow \infty} a_n < \limsup_{n \rightarrow \infty} a_n$, 即必存在二实数 a, b , 使

$$\liminf_{n \rightarrow \infty} a_n \leq a < b \leq \limsup_{n \rightarrow \infty} a_n.$$

用图形来直观解释 (如图 4.4.1), 就是 $\{a_n\}$ 无穷多次到达 a 之下, b 之上. 即 $\{a_n\}$ 上穿 (a, b) 无穷多次. 于是研究 $\{X_n\}$ 的收敛性就要研究穿越 (a, b) 的次数问题.




图 4.4.1

引理 4.4.1 设 $\{X_n\}$ 是关于 $\{Y_n\}$ 的下鞅, S, T 是关于 $\{Y_n\}$ 的停时, 假定 $0 \leq S \leq T \leq N$, 则

$$EX_S \leq EX_T. \quad (4.4.1)$$

证: 设 k 固定, $k \leq n$. 因为 $I_{\{T > n\}}$ 仅仅依赖于 Y_0, Y_1, \dots, Y_n , 利用条件期望的性质可得

$$\begin{aligned} E(X_{n+1} \cdot I_{\{T > n\}} \cdot I_{\{S=k\}}) &= E\{E[X_{n+1} \cdot I_{\{T > n\}} \cdot I_{\{S=k\}} | Y_0, Y_1, \dots, Y_n]\} \\ &= E\{E(X_{n+1} | Y_0, Y_1, \dots, Y_n) \cdot I_{\{T > n\}} \cdot I_{\{S=k\}}\} \\ &\geq E(X_n \cdot I_{\{T > n\}} \cdot I_{\{S=k\}}). \end{aligned}$$

故

$$\begin{aligned}
 E[X_{T \wedge n} \cdot I_{\{S=k\}}] &= E[X_T \cdot I_{\{T \leq n\}} \cdot I_{\{S=k\}}] + E[X_n \cdot I_{\{T > n\}} \cdot I_{\{S=k\}}] \\
 &\leq E[X_T \cdot I_{\{T \leq n\}} \cdot I_{\{S=k\}}] + E[X_{n+1} \cdot I_{\{T > n\}} \cdot I_{\{S=k\}}] \\
 &= E[X_{T \wedge (n+1)} \cdot I_{\{T \leq n\}} \cdot I_{\{S=k\}}] + E[X_{T \wedge (n+1)} \cdot I_{\{T > n\}} \cdot I_{\{S=k\}}] \\
 &= E[X_{T \wedge (n+1)} \cdot I_{\{S=k\}}].
 \end{aligned}$$

因此 $E[X_{T \wedge n} \cdot I_{\{S=k\}}]$ 对于 n 是单调增函数.

由假设 $S \leq T$, 故

$$E(X_S \cdot I_{\{S=k\}}) \leq E(X_T \cdot I_{\{S=k\}}).$$

因此

$$\begin{aligned}
 EX_S &= E\left(\sum_{k=0}^N X_S \cdot I_{\{S=k\}}\right) = \sum_{k=0}^N E(X_S \cdot I_{\{S=k\}}) \\
 &\leq \sum_{k=0}^N E(X_T \cdot I_{\{S=k\}}) = E\left(X_T \cdot \sum_{k=0}^N I_{\{S=k\}}\right) = EX_T. \quad \square
 \end{aligned}$$

设 $\{X_n\}$ 是随机序列, 令 $V^{(n)}(a, b)(\omega)$ 是 $(X_0(\omega), X_1(\omega), \dots, X_n(\omega))$ 向上穿越 (a, b) 的次数. 令 $\alpha_0 = 0$, 记 α_1 为 $\{X_n\}$ 首次到达 $(-\infty, a]$ 的时间, α_2 是 α_1 之后首次到达 $[b, +\infty)$ 的时间, 即

$$\begin{aligned}
 \alpha_1 &= \min\{n : n \geq 0, X_n \leq a\}, \\
 \alpha_2 &= \min\{n : n > \alpha_1, X_n \geq b\}.
 \end{aligned}$$

依次类推, 归纳定义为

$$\begin{aligned}
 \alpha_{2k-1} &= \min\{n : n \geq \alpha_{2k-2}, X_n \leq a\}, \\
 \alpha_{2k} &= \min\{n : n > \alpha_{2k-1}, X_n \geq b\}.
 \end{aligned}$$

显然, 当且仅当 $\alpha_{2l} \leq n \leq \alpha_{2(l+1)}$ 时, $V^{(n)}(a, b)(\omega) = l$.

引理 4.4.2 (上穿不等式) 设 $\{X_n, n \geq 0\}$ 关于 $\{Y_n, n \geq 0\}$ 是下鞅, $V^{(n)}(a, b)$ 表示 X_k 上穿区间 (a, b) 的次数, $k = 0, 1, \dots, n$. 则

$$E(V^{(n)}(a, b)) \leq \frac{E(X_n - a)^+ - E(X_0 - a)^+}{b - a} \leq \frac{EX_n^+ + |a|}{b - a} \quad (4.4.2)$$

这里记 $a^+ = \max(a, 0) = a \vee 0$.

证: 因为 $\{X_n\}$ 关于 $\{Y_n\}$ 是下鞅. 因此 $\{(X_n - a)^+\}$ 关于 $\{Y_n\}$ 也是下鞅. 这是因为

$$E|(X_n - a)^+| \leq E|X_n| + |a| < \infty,$$

4.4 鞅收敛定理

$$\begin{aligned}
 E\{(X_{n+1} - a)^+ | Y_0, Y_1, \dots, Y_n\} &= E(X_{n+1} \vee a - a | Y_0, Y_1, \dots, Y_n) \\
 &= E(X_{n+1} \vee a | Y_0, Y_1, \dots, Y_n) - a \\
 &= E(X_{n+1} | Y_0, Y_1, \dots, Y_n) \vee a - a \\
 &\geq X_n \vee a - a = (X_n - a)^+.
 \end{aligned}$$

另外 $\{(X_k - a)^+, 0 \leq k \leq n\}$ 上穿过区间 $(0, b - a)$ 的次数也为 $V^{(n)}(a, b)$.

令 $\beta_k = \alpha_k \wedge n, (k \geq 0)$. $\tilde{X}_n = (X_n - a)^+$. 由前面结果可知 $\{\tilde{X}_n\}$ 关于 $\{Y_n\}$ 是下鞅.

因为所有的 $\alpha_k (k \geq 0)$ 都是 $\{X_n\}$ 的停时, 因此也是 $\{Y_n\}$ 的停时, 所以 $\beta_k (k \geq 0)$ 也是 $\{Y_n\}$ 的停时. 根据引理 4.4.1, 有

$$E(\tilde{X}_{\beta_k} - \tilde{X}_{\beta_{k-1}}) \geq 0.$$

故

$$E(\tilde{X}_n - \tilde{X}_0) = \sum_{k=1}^{\infty} E(\tilde{X}_{\beta_k} - \tilde{X}_{\beta_{k-1}}) \geq \sum_{m=1}^{\infty} E(\tilde{X}_{\beta_{2m}} - \tilde{X}_{\beta_{2m-1}}).$$

当 $V^{(n)}(a, b) \geq m$ 时, $(\tilde{X}_{\beta_{2m}} - \tilde{X}_{\beta_{2m-1}})$ 才为非零, 且其至少为 $b - a$. 即

$$(\tilde{X}_{\beta_{2m}} - \tilde{X}_{\beta_{2m-1}}) \geq (b - a)I_{(V^{(n)}(a, b) \geq m)}.$$

因此

$$\begin{aligned}
 E(\tilde{X}_n - \tilde{X}_0) &\geq (b - a)E\left[\sum_{m=1}^{\infty} I_{(V^{(n)}(a, b) \geq m)}\right] \\
 &= (b - a) \sum_{m=1}^{\infty} P(V^{(n)}(a, b) \geq m) = (b - a)E\{V^{(n)}(a, b)\}.
 \end{aligned}$$

于是有

$$E\{V^{(n)}(a, b)\} \leq \frac{E(\tilde{X}_n - \tilde{X}_0)}{b - a} = \frac{E(X_n - a)^+ - E(X_0 - a)^+}{b - a} \leq \frac{EX_n^+ + |a|}{b - a}. \quad \square$$

推论: $\{X_n, n \geq 0\}$ 是关于 $\{Y_n, n \geq 0\}$ 的上鞅, $\bar{V}^{(n)}(a, b)$ 是 X_n 下穿 (a, b) 的次数, 则

$$E(\bar{V}^{(n)}(a, b)) \leq \frac{1}{b - a}[E(b \wedge X_0) - E(X_n \wedge b)]. \quad (4.4.3)$$

如果 $X_n \geq 0, b > a \geq 0$, 则

$$E(\bar{V}^{(n)}(a, b)) \leq \frac{b}{b - a}. \quad \square$$

133

下面证明在什么情况下, 一个鞅 $\{X_n\}$ 在 $n \rightarrow \infty$ 时将趋向一个期望有限的随机变量.

定理 4.4.1 设 $\{X_n\}$ 是一个下鞅. $\sup_n E|X_n| < \infty$, 则存在一随机变量 X_∞ , 使 $\{X_n\}$ 以概率 1 收敛于 X_∞ . 即

$$P(\lim_{n \rightarrow \infty} X_n = X_\infty) = 1. \quad (4.4.4)$$

且 $E|X_\infty| < \infty$.

证: 首先, 由于

$$EX_n^+ \leq E|X_n| \leq 2EX_n^+ - EX_n.$$

故

$$\sup_n E|X_n| < \infty \text{ 当且仅当 } \sup_n EX_n^+ < \infty.$$

另一方面, 当 $n \rightarrow \infty$ 时, $V^{(n)}(a, b) \rightarrow V(a, b) = \{X_n \text{ 上穿}(a, b) \text{ 的次数}\}$. 故

$$\begin{aligned} E(V(a, b)) &= E\{\lim_n V^{(n)}(a, b)\} = \lim_{n \rightarrow \infty} E(V^{(n)}(a, b)) \\ &\leq \lim_n \frac{EX_n^+ + |a|}{b - a} \leq \frac{\sup_n EX_n^+ + |a|}{b - a} < \infty. \end{aligned}$$

因此

$$P(V(a, b) < \infty) = 1.$$

从而

$$P(V(a, b) = +\infty) = 0.$$

于是

$$\begin{aligned} &P\{\omega : n \rightarrow \infty \text{ 时 } X_n(\omega) \text{ 无极限}\} \\ &= P\left(\bigcup_{a < b \text{ 且为有理数}} \{\omega : \liminf_{n \rightarrow \infty} X_n(\omega) \leq a < b < \limsup_{n \rightarrow \infty} X_n(\omega)\}\right) \\ &= P\left(\bigcup_{a < b \text{ 且为有理数}} \{\omega : V(a, b) = +\infty\}\right) = 0. \end{aligned}$$

因此

$$P(\omega : n \rightarrow \infty \text{ 时 } X_n(\omega) \text{ 有极限}) = 1.$$

设 $\lim_{n \rightarrow \infty} X_n(\omega) = X_\infty(\omega)$, 则

$$P\{\omega : \lim_{n \rightarrow \infty} X_n(\omega) = X_\infty(\omega)\} = 1.$$

另外, 由 Fatou 引理

$$E|X_\infty| = E(\lim_{n \rightarrow \infty} |X_n|) \leq \lim_{n \rightarrow \infty} E|X_n| \leq \sup_n E|X_n| < \infty,$$

4.4 鞅收敛定理

即

$$E|X_\infty| < \infty. \quad \square$$

有关鞅的收敛定理内容极其丰富. 下面再介绍一个有名的最大值不等式与另一个收敛定理.

最大值不等式 (The maximal inequality).

我们知道, 当 $Y_0, Y_1, \dots, Y_n, \dots$ 独立同分布, 且 $EY_i = 0, EY_i^2 = \sigma^2 (i \geq 0), X_0 = 0, X_n = \sum_{i=1}^n Y_i$ 时, 对任意 $\varepsilon > 0$, 根据 Chebyshev 不等式, 有

$$\varepsilon^2 P(|X_n| > \varepsilon) \leq n\sigma^2.$$

根据 Kolmogorov 不等式, 有

$$\varepsilon^2 P(\max_{0 \leq k \leq n} |X_k| > \varepsilon) \leq n\sigma^2. \quad (4.4.5)$$

这些不等式应用到鞅中将非常简单而有效.

引理 4.4.3 设 $\{X_n\}$ 是下鞅, 且 $\forall n \geq 0, X_n \geq 0$, 则对任何 $\lambda > 0$, 有

$$\lambda P(\max_{0 \leq k \leq n} X_k > \lambda) \leq EX_n. \quad (4.4.6)$$

证: 令 $T = \min\{k : k \geq 0, X_k > \lambda\}$, 则 $X_T > \lambda$. 利用引理 4.4.1 得

$$EX_n \geq EX_{T \wedge n} \geq E(X_{T \wedge n} \cdot I_{(\max_{0 \leq k \leq n} X_k > \lambda)}).$$

注意到当 $\{\max_{0 \leq k \leq n} X_k > \lambda\}$ 事件发生时, $T \leq n$, 于是有 $T \wedge n = T$, 故

$$EX_n \geq E(X_T \cdot I_{(\max_{0 \leq k \leq n} X_k > \lambda)}) \geq \lambda E(I_{(\max_{0 \leq k \leq n} X_k > \lambda)}) = \lambda P(\max_{0 \leq k \leq n} X_k > \lambda). \quad \square$$

推论: 设 $\{X_n\}$ 是鞅, 则对任意 $\lambda > 0$, 有

$$\lambda P(\max_{0 \leq k \leq n} |X_k| > \lambda) \leq E|X_n|.$$

证: 只要证明 $|X_n| \geq 0$ 是个下鞅, 利用引理 4.4.3 即可证明. 因为 $\{X_n\}$ 是鞅, 因此

$$E||X_n|| = E|X_n| < \infty,$$

$$E(|X_{n+1}| | Y_0, \dots, Y_n) \geq |E(X_{n+1} | Y_0, \dots, Y_n)| = |X_n|.$$

故 $\{|X_n|\}$ 是下鞅. 由引理 4.4.3 得

$$\lambda P(\max_{0 \leq k \leq n} |X_k| > \lambda) \leq E|X_n|. \quad \square$$

定理 4.4.2 设 $\{X_n\}$ 关于 $\{Y_n\}$ 是鞅, 且存在一常数 k , 使 $\forall n, EX_n^2 \leq k < \infty$, 则存在一有限随机变量 X_∞ , 使得

$$P(\lim_{n \rightarrow \infty} X_n = X_\infty) = 1,$$

$$\lim_{n \rightarrow \infty} E|X_n - X_\infty|^2 = 0.$$

更一般地,

$$EX_0 = EX_n = EX_\infty, \quad \forall n.$$

证: 本定理证明较长, 在此略去. 有兴趣的读者可参看 [2]. □

§ 4.5 连续参数鞅

定义 $\{X(t), t \geq 0\}$ 是一随机过程, 记 $\mathcal{F}_t = \sigma(X(s), 0 \leq s \leq t)$. 过程 $\{X(t), t \geq 0\}$ 是鞅, 如果

1° $\forall t \geq 0$, 有 $E|X(t)| < \infty$,

2° $\forall s, t \geq 0$, 有 $E(X(t+s)|\mathcal{F}_t) = X(t)$ a.s. (几乎处处).

3° $\forall t \geq 0$, $X(t)$ 关于 \mathcal{F} 是可测的. □

将这一定义离散化, 则可写为

定义 随机过程 $\{X(t), t \geq 0\}$ 是鞅, 如果

1° $\forall t \geq 0$, 有 $E|X(t)| < \infty$,

2° $\forall 0 \leq t_0 < t_1 < \cdots < t_n < t_{n+1}$, 有 $E(X(t_{n+1})|X(t_1), \dots, X(t_n)) = X(t_n)$ a.s. (几乎处处). □

同样可以对连续参数定义上鞅和下鞅.

与离散的情形类似, 连续参数鞅的停时定义为:

定义 设有非负随机变量 T , 及随机序列 $\{X(t), t \geq 0\}$, $\mathcal{F}_t = \sigma(X(s), 0 \leq s \leq t)$. 若对 $\forall t \geq 0$, $\{T \leq t\} \in \mathcal{F}_t$, 称则 T 是 $\{X(t), t \geq 0\}$ 的停时. □

停时定理 设 $\{X(t), t \geq 0\}$ 是鞅, T 是停时, 若 $P(T < \infty) = 1$; 且

$$E(\sup_{t \geq 0} |X_{T \wedge t}|) < \infty,$$

则

$$EX(T) = EX(0).$$

定理的证明与离散鞅停时定理的证明类似, 留给读者作为练习.

例 1 设 $\{N(t), t \geq 0\}$ 是时齐 Poisson 过程, 参数为 $\lambda, \lambda > 0$ 令 $X(t) = N(t) - \lambda t, Y(t) = X^2(t) - \lambda t, U(t) = \exp(-\theta X(t) + \lambda(1 - e^{-\theta}))$, θ 为参数, $-\infty < \theta < \infty$. 则 $X(t), Y(t), U(t)$ 是鞅.

练习题

练习题

4.1 设 $\{Y_n, n \geq 1\}$ iid, 且 $P(Y_n = 1) = p \geq 0, P(Y_n = -1) = q \geq 0, p + q = 1, p - q > 0, Y_0 = 0$, 令

$$X_0 = 0, \quad X_n = \sum_{k=1}^n Y_k, \quad U_n = X_n - n(p-q), \quad V_n = \left(\frac{q}{p}\right)^{X_n}, \quad W_n = U_n^2 - n[1 - (p-q)^2].$$

1. 证 $\{U_n, n \geq 0\}, \{V_n, n \geq 0\}, \{W_n, n \geq 0\}$ 关于 $\{Y_n, n \geq 0\}$ 是鞅;
2. 证 $\{X_n, n \geq 0\}$ 关于 $\{Y_n, n \geq 0\}$ 是下鞅;
3. 求 U_m 与 U_{m+n} 的相关系数;
4. 求 $E(U_3|X_2)$ 的分布律并证明 $E(U_{n+k}|X_n) = U_n, \forall x \geq 0$;
5. 求 $E(V_8|X_7 = 3)$.

4.2 设 $Y_0 = 0, \{Y_n, n \geq 1\}$ iid,

1. 若 $EY_n = 0, EY_n^2 = \sigma^2$. 令

$$X_0 = 0, \quad X_n = \left(\sum_{k=1}^n Y_k\right)^2 - n\sigma^2.$$

证明 $\{X_n, n \geq 0\}$ 关于 $\{Y_n, n \geq 0\}$ 是鞅.

2. 若 $Y_n \sim N(0, \sigma^2), X_n = \exp\{\frac{\mu}{\sigma^2} \sum_{k=1}^n Y_k - \frac{n\mu^2}{2\sigma^2}\}, n \geq 1, X_0 = 0$. 证明 $\{X_n, n \geq 0\}$ 关于 $\{Y_n, n \geq 0\}$ 是鞅.

4.3 (续 4.1) 令 a, b 为正整数,

$$T_b = \min\{n : n \geq 1, X_n = b\}, \quad T = \min\{n : X_n = -a, \text{ 或 } X_n = b\}.$$

试证

$$\begin{aligned} ET_b &= \frac{b}{p-q}, \\ ET &= \frac{b}{p-q} - \frac{a+b}{p-q} \cdot \frac{1 - (p/q)^b}{1 - (p/q)^{a+b}}, \\ \text{Var } T_b &= \frac{b[1 - (p-q)^2]}{(p-q)^3}. \end{aligned}$$

4.4 设随机变量序列 $\{X_n, n \geq 0\}$, 满足 $E|X_n| < \infty$, 且

$$E[X_{n+1}|X_0, X_1, \dots, X_n] = \alpha X_n + \beta X_{n-1}, \quad n > 0, \beta, \alpha > 0, \alpha + \beta = 1.$$

137

令 $Y_n = \alpha X_n + X_{n-1}, n \geq 1, Y_0 = X_0$. 试选择合适的 a 使得 $\{Y_n, n \geq 0\}$ 关于 $\{X_n, n \geq 0\}$ 是鞅.

4.5 设 $\{X_n, n \geq 0\}$ 关于 $\{Y_n, n \geq 0\}$ 是鞅. 证明对任何整数集 $k \leq l < m$, $X_m - X_l$ 与 X_k 不相关, 即 $E[(X_m - X_l)X_k] = 0$.

4.6 设 $\{X_n, n \geq 0\}$ 是鞅, 而 $\{\xi_i, i \geq 0\}$ 由下式部分和确定, $X_n = \sum_{i=0}^n \xi_i$. 试证 $\forall j \neq i, E\{\xi_i \xi_j\} = 0$.

4.7 设 $\forall n \geq 1, EX_n^2 \leq k < \infty$. 令 $S_n = \sum_{k=1}^n X_k$. 已知 $\{S_n, n \geq 1\}$ 是鞅. 证明 $\forall \varepsilon > 0$,

$$\lim_{n \rightarrow \infty} P\left(\left|\frac{S_n}{n}\right| > \varepsilon\right) = 0.$$

(提示: 利用最大不等式与习题 4.6 的结果).

4.8 设 Y_0 服从 $(0, 1)$ 上均匀分布. 且给定 Y_n 时, Y_{n+1} 是 $(1 - Y_n, 1]$ 上的均匀分布. 令 $X_0 = Y_0$,

$$X_n = 2^n \prod_{k=1}^n \left[\frac{1 - Y_k}{Y_{k-1}} \right], \quad n = 1, 2, \dots$$

证明 $\{X_n, n \geq 0\}$ 关于 $\{Y_n, n \geq 0\}$ 是鞅.

4.9 设 $\{X_n, n \geq 0\}$ 是 M.C., 状态空间为 $S = \{0, 1, 2, \dots, N\}$.

1. 若

$$p_{ij} = C_N^j \left(\frac{i}{N}\right)^j \left(1 - \frac{i}{N}\right)^{N-j}, \quad V_n = \frac{X_n(N - X_n)}{(1 - N^{-1})^n}.$$

试证 $\{X_n, n \geq 0\}$ 与 $\{V_n, n \geq 0\}$ 关于 $\{X_n, n \geq 0\}$ 是鞅.

2. 若

$$p_{ij} = \frac{C_{2i}^j C_{2N-2i}^{N-j}}{C_{2N}^N}, \quad W_n = X_n \frac{(N - X_n)}{\lambda^n}, \quad n \geq 0.$$

试确定 λ , 使 $\{W_n, n \geq 0\}$ 关于 $\{X_n, n \geq 0\}$ 是鞅.

4.10 设 $\{X_n, n \geq 0\}$ 是 M.C., $S = \{0, 1, 2, \dots\}$, $p_{ij} = \frac{i^j}{j!} e^{-i}$, $i, j \in S$.

1. 证明 $\{X_n, n \geq 0\}$ 是鞅;

2. 对 $i, a = 1, 2, \dots$, 证明 $P(\max_{0 \leq n < \infty} X_n \geq a | X_0 = i) \leq \frac{i}{a}$;

3. 证明 $P(\lim_{n \rightarrow \infty} X_n = 0) = 1$.

(提示: 令 $T = \min\{n : n \geq 0, X_n = 0 \text{ 或 } X_n = a\}$, 然后利用停时定理.)

4.11 设 $\{X_n, n \geq 0\}$ 为 M.C., $S = \{0, 1, 2, \dots\}$, $p_{ij} = 1/[e(j-i)!]$, $i \in S, j \geq i$. 试证 $\{Y_n = X_n - n, n \geq 0\}$, $\{U_n = Y_n^2 - n, n \geq 0\}$ 及 $\{V_n = \exp(X_n - n(e-1)), n \geq 0\}$ 是鞅.

4.12 设 $\{X_n, n \geq 1\}$ 是下鞅. 令

$$U_1 = 0, \quad U_n = \sum_{i=2}^n \{E[X_i | X_1, X_2, \dots, X_{i-1}] - X_{i-1}\}, \quad n \geq 2.$$

试证 $\{U_n, n \geq 1\}$ 是单调增过程, 即 $U_n \geq U_{n-1}$.

练习题

4.13 设 $\{X_n, n \geq 0\}$ 是 M.C., $S = \{0, 1, 2, \dots\}$, $\mathbf{P} = (p_{ij})$, $\mathbf{P}^{(m)} = (p_{ij}^{(m)})$. 且 $u(i, n)$ 对 $\forall i, n \in S$, 满足

$$u(i, n) = \sum_{k=0}^{\infty} u(k, n+m) p_{ik}^{(m)}.$$

记 $U_n = u(X_n, n)$. 证明 $\{U_n, n \geq 0\}$ 是鞅.

4.14 设 $\{U_n\}$, $\{V_n\}$ 关于 $\{Y_n\}$ 是鞅, $U_0 = V_0 = 0$, $EU_n^2 < \infty$, $EV_n^2 < \infty$. 证明

$$\begin{aligned} E(U_n V_n) &= \sum_{k=1}^n E[(U_k - U_{k-1})(V_k - V_{k-1})], \\ EU_n^2 &= \sum_{k=1}^n E[(U_k - U_{k-1})^2]. \end{aligned}$$

4.15 设 $\{X_n, n \geq 0\}$ 是鞅, 且对某一 $\alpha > 1$, $E[|X_n|^\alpha] < \infty$, $\forall n \geq 0$. 证明

$$E[\max_{0 \leq k \leq n} |X_k|] \leq \frac{\alpha}{\alpha - 1} [E|X_n|^\alpha]^{1/\alpha}.$$

(提示 $E[\max_{0 \leq k \leq n} |X_k|] = \int_0^\infty P(\max_{0 \leq k \leq n} |X_k| > t) dt$, 并利用最大不等式于下鞅 $\{|X_n|^\alpha, n \geq 0\}$.)

4.16 设 $\{X_n\}$ 是非负上鞅, 证明 $\forall \lambda > 0$,

$$\lambda P(\max_{0 \leq k \leq n} X_k \geq \lambda) \leq EX_0.$$

4.17 设 $\{X_n\}$ 是下鞅, 证明 $\forall \lambda > 0$,

$$\lambda P\{\max_{0 \leq k \leq n} X_k < -\lambda\} \leq EX_n^+ - EX_0.$$

4.18 设 $\{X_n\}$ 是鞅, 且 $EX_n = 0$, $E(X_n^2) < \infty$. 证明 $\forall \lambda > 0$,

$$P\{\max_{0 \leq k \leq n} X_k > \lambda\} \leq \frac{EX_n^2}{EX_n^2 + \lambda^2}.$$

(提示: 对 $\forall c > 0$, $\{(X_n + c)^2\}$ 是下鞅, 利用最大不等式, 对 $\forall \lambda > 0$,

$$P\{\max_{0 \leq k \leq n} X_k > \lambda\} \leq P\{\max_{0 \leq k \leq n} (X_k + c)^2 > (\lambda + c)^2\} \leq \frac{E[(X_n + c)^2]}{(\lambda + c)^2}, \quad \forall c > 0.$$

再选 c 使上不等式右边最小.)

4.19 设 $\{X_n\}$ 对于固定的 $\lambda > 0$, 满足 $E\{\exp(\lambda X_{n+1}) | X_1, \dots, X_n\} \leq 1 \quad \forall n \geq 1$. 令 $S_0 = 0$, $S_n = \sum_{k=1}^n X_k$. 证明

139

$$P(\sup_{n \geq 0} (x + S_n) > l) \leq e^{-\lambda(l-x)}, \quad x \leq l.$$

(提示: 对非负上鞅 $\{\exp(-\lambda(l-x-S_n))\}$ 利用停时定理.)

4.20 设 X 是 r.v., 对给定的 $\varepsilon > 0$, $\rho > 0$, 有 $P(-\varepsilon \leq X \leq \varepsilon) = 1$, $EX \leq -\rho\varepsilon$. 证明对 $\lambda = \varepsilon^{-1} \log[(1+\rho)/(1-\rho)]$, 有

$$E(e^{\lambda X}) \leq 1.$$

若对 $\{X_n\}$, $S_0 = 0$, $S_n = \sum_{k=1}^n X_k$, 满足对给定 $\varepsilon > 0$, $\rho > 0$, 有

$$P\{-\varepsilon \leq X_{n+1} \leq \varepsilon | X_1, X_2, \dots, X_n\} = 1, \quad E\{X_{n+1} | X_1, \dots, X_n\} \leq -\rho\varepsilon.$$

试利用习题 4.19 的结果, 给出当 $x < l$ 时, $P(\sup_{n \geq 0}(x + S_n) > l)$ 的界限.

4.21 设 $\{X_n\}$ 满足 $EX_n = 0$, $EX_n^2 < \infty$. 记 $S_n = \sum_{k=1}^n X_k$. $\{S_n\}$ 是关于 $\{X_n\}$ 的鞅, 证明对任一满足 $0 < b_n \leq b_{n+1} \uparrow \infty$, $\sum_{n=1}^{\infty} E[X_n^2]/b_n^2 < \infty$ 的单调正序列 $\{b_n, n \geq 1\}$ 有

$$P\left(\lim_{n \rightarrow \infty} \frac{S_n}{b_n} = 0\right) = 1.$$

4.22 设 $\{X_n, n \geq 0\}$ 是 M.C., $\mathbf{P} = (p_{ij})$, $f(i)$ 是定义在 S 上的有界函数. 令 $F(i) = \sum_{j \in S} p_{ij} f(j) - f(i)$, $i \in S$. 证明

$$P\left\{\lim_{n \rightarrow \infty} \frac{\sum_{k=1}^n F(X_k)}{n} = 0\right\} = 1.$$

(提示: 利用习题 4.21 的结果.)

4.23 设 $\{X_n, n \geq 0\}$ 关于 $\{Y_n, n \geq 0\}$ 是鞅, c 是任意常数.

1. 若 $E|X_n \vee c| < +\infty$, 则 $\{X_n \vee c, n \geq 0\}$ 是下鞅;
2. 若 $EX_n^+ < +\infty$, 则 $\{X_n^+, n \geq 0\}$ 是下鞅.

4.24 设 $\{X_n, n \geq 0\}$ 关于 $\{Y_n, n \geq 0\}$ 是上鞅.

1. 若 $E|X_n \wedge c| < +\infty$, 则 $\{X_n \wedge c, n \geq 0\}$ 是上鞅;
2. 若 $EX_n^- > -\infty$, 则 $\{X_n^-, n \geq 0\}$ 是上鞅.

第五章 Brown 运动

Brown 运动 (Brown Motion) 最初是由英国生物学家 R. Brown 于 1827 年根据观察花粉微粒在液面上作“无规则运动”的物理现象而提出的. Einstein 于 1905 年首次对这一现象的物理规律给出了一种数学描述, 使这一课题有了显著的发展. 这方面的物理理论工作在 Smoluchowski, Fokker, Planck, Burger, Furth Ornstein, Ublenbeck 等人的努力下迅速发展起来了. 但数学方面却由于精确描述太困难而进展缓慢, 直到 1918 年才由 Wiener 对这一现象在理论上作出了精确数学描述. 并进一步研究了 Brown 运动轨道的性质, 提出了在 Brown 运动空间上定义测度与积分. 使对 Brown 运动及其泛涵的研究得到迅速而深入的发展, 并逐渐渗透到概率论及数学分析的各个领域, 使之成为现代概率论的重要部分.

Brown 运动作为具有连续时间参数和连续状态空间的一个随机过程, 是一个最基本, 最简单同时又是最重要的过程. 许多其它的过程常常可以看作是它的泛函或某种意义上的推广. 它又是迄今了解得最清楚, 性质最丰富多彩的随机过程之一. 今天, Brown 运动及其推广已广泛地出现在许多纯科学领域中, 如物理, 经济, 通讯理论, 生物, 管理科学与数理统计等. 同时, 由于 Brown 运动与微分方程 (如热传导方程) 有密切的联系, 它又成为概率与分析联系的重要渠道. 在这一章里, 我们仅对 Brown 运动作一简要的介绍.

§ 5.1 随机游动与 Brown 运动的定义

让我们考虑在一直线上的简单的, 对称的随机游动. 设质点每经过一单位时间 Δt , 随机地以概率 $p = \frac{1}{2}$ 向右移 $\Delta x > 0$ 单位, 以概率 $q = \frac{1}{2}$ 向左移动一个 Δx 单位, 且每次移动相互独立, 记:

$$X_i = \begin{cases} 1, & \text{第 } i \text{ 次质点向右移动} \\ -1, & \text{第 } i \text{ 次质点向左移动} \end{cases}$$

若 $X(t)$ 表示 t 时刻质点的位置, 则有:

$$X(t) = \Delta x (X_1 + X_2 + \cdots + X_{[\frac{t}{\Delta t}]})$$

其中, $[S]$ 为不超过 S 的最大整数.

显然, $EX_i = 0, DX_i = EX_i^2 = 1$, 故此时:

$$EX(t) = 0, \quad DX(t) = (\Delta x)^2 \cdot \left[\frac{t}{\Delta t} \right].$$

141

以上简单随机游动可作为微小粒子在直线上作不规则运动的近似. 实际粒子的不规则运动是连续进行的. 为此, 我们考虑让 $\Delta t \rightarrow 0$ 的极限情形. 由物理实验得知, 当 Δt 越

小时, 每次移动 Δx 也越小, 通常有 $\Delta t \rightarrow 0, \Delta x \rightarrow 0$. 而且在许多情形下, 有 $\Delta x = c \cdot \sqrt{\Delta t}$ ($c > 0$ 为常数). 因此, 我们下面先假定在 $\Delta x = c \cdot \sqrt{\Delta t}$ 的条件下, 推出其极限情形.

显然, 当 $\Delta t \rightarrow 0$ 时, $EX(t) = 0$, 而

$$\lim_{\Delta t \rightarrow 0} DX(t) = \lim_{\Delta t \rightarrow 0} (\Delta x)^2 \left[\frac{t}{\Delta t} \right] = \lim_{\Delta t \rightarrow 0} c^2 \cdot \Delta t \left[\frac{t}{\Delta t} \right] = c^2 \cdot t.$$

另一方面, $X(t) = \Delta x(X_1 + X_2 + \cdots + X_{[\frac{t}{\Delta t}]})$ 可看作是独立同分布的随机变量之和, 因而是独立增量过程, 即 $X(t)$ 看作是由许多微小的相互独立的随机变量 $X(t_i) - X(t_{i-1})$ 组成之和. 故当 $\Delta t \rightarrow 0$ 时, 由中心极限定理知, $X(t)$ 经标准化以后, 它的分布趋向标准正态分布, 即

若 $\forall x \in \mathbb{R}, t > 0, \Phi(x)$ 为标准正态函数, 有

$$\lim_{\Delta t \rightarrow 0} P \left\{ \frac{\sum_{i=0}^{[\frac{t}{\Delta t}]} \Delta x \cdot X_i - 0}{\sqrt{c^2 \cdot t}} \leq x \right\} = \Phi(x).$$

等价于 $\lim_{\Delta t \rightarrow 0} P \left\{ \frac{X(t)}{\sqrt{c^2 \cdot t}} \leq x \right\} = \Phi(x) = \frac{1}{\sqrt{2\pi}} \cdot \int_{-\infty}^x e^{-\frac{u^2}{2}} du.$

故 $X(t)$ 趋向正态分布. 即:

$$\Delta t \rightarrow 0 \text{ 时, } X(t) \sim N(0, c^2 t).$$

有了上述由简单随机游动的极限来描述的质点在一维直线上作不规则运动的直观数学描述, 就可以引出以下的定义.

定义 1 若一个随机过程 $\{X(t), t \geq 0\}$ 满足

1° $X(t)$ 是独立增量过程;

2° $\forall s, t > 0, X(s+t) - X(s) \sim N(0, c^2 t)$, 即 $X(s+t) - X(s)$ 是期望为 0, 方差为 $c^2 t$ 的正态分布;

3° $X(t)$ 关于 t 是连续函数.

则称 $\{X(t), t \geq 0\}$ 是 Brown 运动(BM) (或 Wiener Process). □

事实上定义中的 3°, 可由定义中的 1°, 2° 推出, 因此 $\{X(t), t \geq 0\}$ 只需满足 1°, 2° 即可判定为 BM. 但为略去不重要的证明及应用的方便, 我们将 3° 所描述的性质放进定义中.

当 $c = 1$ 时, 称 $\{X(t), t \geq 0\}$ 为 **标准 Brown 运动**. 此时若 $X(0) = 0, X(t) \sim N(0, t)$.

Brown 运动一般简记为 BM. 下面我们仅讨论标准 BM 的情形, 记之为 $\{B(t), t \geq 0\}$. 它在 t 时刻的概率密度函数为:

142

$$f_t(x) = \frac{1}{\sqrt{2\pi t}} e^{-\frac{x^2}{2t}}. \quad (5.1.1)$$

5.1 随机游动与 Brown 运动的定义

下面讨论 $B(t)$ 的联合分布及其重要性质.

1. $B(t)$ 的联合概率密度

先回顾一下随机向量变换的重要公式:

设 $X = (X_1, X_2, \dots, X_n)$ 为 n 维随机向量, 其概率密度函数 p.d.f. 为 $f(x_1, x_2, \dots, x_n)$. 现有 $Y_i = g_i(X_1, X_2, \dots, X_n) (i = 1, 2, \dots, n)$ 是 X 的函数, 且存在唯一反函数 $X_i = h_i(Y_1, Y_2, \dots, Y_n) (i = 1, 2, \dots, n)$. 如果 g_i, h_i 有连续偏导数, 则 $Y = (Y_1, Y_2, \dots, Y_n)$ (其中 $Y_i = g_i(X_1, X_2, \dots, X_n)$) 的概率密度函数 p.d.f. 为:

$$g(y_1, y_2, \dots, y_n) = \begin{cases} f(x_1, x_2, \dots, x_n) \cdot |J|, & \text{若 } y_1, y_2, \dots, y_n \text{ 是 } g_1, g_2, \dots, g_n \text{ 的值域, 且 } |J| \neq 0. \\ 0, & \text{其它.} \end{cases} \quad (5.1.2)$$

这里

$$x_i = h_i(y_1, y_2, \dots, y_n), \quad (1 \leq i \leq n)$$

其中 J 为坐标变换的雅可比行列式, 即

$$J = \begin{vmatrix} \frac{\partial x_1}{\partial y_1} & \frac{\partial x_1}{\partial y_2} & \dots & \frac{\partial x_1}{\partial y_n} \\ \vdots & \vdots & & \vdots \\ \frac{\partial x_n}{\partial y_1} & \frac{\partial x_n}{\partial y_2} & \dots & \frac{\partial x_n}{\partial y_n} \end{vmatrix}$$

由 $B(t_2) - B(t_1) \sim N(0, t_2 - t_1)$, 知其概率密度函数 p.d.f. 为:

$$p(x, t_2 - t_1) = \frac{1}{\sqrt{2\pi(t_2 - t_1)}} \exp\left\{-\frac{x^2}{2(t_2 - t_1)}\right\}. \quad (5.1.3)$$

有了上述的结论, 我们讨论下面的定理.

定理 5.1.1 设 $\{B(t), t \geq 0\}$ 为标准 BM, 则当 $B(0) = 0$ 时, $\forall 0 \leq t_1 < t_2 < \dots < t_n$, $(B(t_1), B(t_2), \dots, B(t_n))$ 的联合概率密度函数为

$$g(x_1, x_2, \dots, x_n; t_1, t_2, \dots, t_n) = \prod_{i=1}^n p(x_i - x_{i-1}; t_i - t_{i-1}) \quad (5.1.4)$$

其中

$$p(x, t) = \frac{1}{\sqrt{2\pi t}} \exp\left\{-\frac{x^2}{2t}\right\}$$

令 $x_0 = 0, t_0 = 0$.

证: 证明的思路是利用 BM 的独立增量性.

令

$$Y_1 = B(t_1), Y_i = B(t_i) - B(t_{i-1}), 2 \leq i \leq n,$$

则

$$B(t_i) = \sum_{k=1}^i Y_k.$$

由 BM 的定义知 Y_1, Y_2, \dots, Y_n 相互独立, 且 $Y_i \sim N(0, t_i - t_{i-1})$, 则其联合概率密度为:

$$f(y_1, y_2, \dots, y_n) = \prod_{i=1}^n \frac{1}{\sqrt{2\pi(t_i - t_{i-1})}} \exp\left\{-\frac{y_i^2}{2(t_i - t_{i-1})}\right\}.$$

由于 $B(t_i) = \sum_{k=1}^i Y_k$, 故可以利用前面引入的随机向量变换的概率密度公式, 得 $B(t_1), B(t_2), \dots, B(t_n)$ 的联合概率密度函数为:

$$g(x_1, x_2, \dots, x_n; t_1, t_2, \dots, t_n) = f(y_1, y_2, \dots, y_n) |J|$$

其中:

$$J = \begin{vmatrix} 1 & 0 & 0 & \cdots & \cdots & 0 \\ -1 & 1 & 0 & \cdots & \cdots & 0 \\ 0 & -1 & 1 & \cdots & \cdots & 0 \\ \vdots & \vdots & \vdots & & & \vdots \\ 0 & 0 & 0 & \cdots & -1 & 1 \end{vmatrix}, \quad \det|J| = 1$$

故

$$\begin{aligned} & g(x_1, x_2, \dots, x_n; t_1, t_2, \dots, t_n) \\ &= \prod_{i=1}^n \frac{1}{\sqrt{2\pi(t_i - t_{i-1})}} \exp\left\{-\frac{(x_i - x_{i-1})^2}{2(t_i - t_{i-1})}\right\} \\ &= \prod_{i=1}^n p(x_i - x_{i-1}, t_i - t_{i-1}). \quad \square \end{aligned}$$

由上述定理很容易得出, 在 $B(t_1) = x_0$ 的条件下, $B(t_2)$ 的条件概率密度函数为:

$$p(x, t_2 - t_1 | x_0) = \frac{1}{\sqrt{2\pi(t_2 - t_1)}} \exp\left\{-\frac{(x - x_0)^2}{2(t_2 - t_1)}\right\} = p(x - x_0, t_2 - t_1).$$

同样, 在 $B(t_0) = x_0$ 下, $B(t_0 + t)$ 的条件概率密度为:

$$p(x, t | x_0) = p(x - x_0, t) = \frac{1}{\sqrt{2\pi t}} \exp\left\{-\frac{(x - x_0)^2}{2t}\right\}. \quad (5.1.5)$$

所以

$$P(B(t_0 + t) > x_0 | B(t_0) = x_0) = P(B(t_0 + t) \leq x_0 | B(t_0) = x_0) = \frac{1}{2}$$

上式表明, 给定初始条件: $B(t_0) = x_0$, 对于任意的 $t > 0$, Brown 运动在 $t_0 + t$ 时刻的位置高于或低于初始位置的概率相等, 均为 $\frac{1}{2}$. 此即 Brown 运动的对称性.

5.1 随机游动与 Brown 运动的定义

容易验证, $p(x, t|x_0)$ 满足下列偏微分方程:

$$\frac{\partial p}{\partial t} = \frac{1}{2} \frac{\partial^2 p}{\partial x^2} \quad (5.1.6)$$

$p(x, t|x_0)$ 有时称为转移概率函数, 表示 t_0 从 x_0 状态出发, 经 t 时间后转移到状态 x 附近 dx 邻域的概率近似为 $p(x, t|x_0) \cdot dx$. 于是:

$$P(B(t_0+t) \leq y | B(t_0) = x_0) = \int_{-\infty}^y p(x, t|x_0) dx.$$

由 (5.1.5) 易知,

$$\forall t \geq 0, \quad P(B(t_0+t) \geq x_0 | B(t_0) = x_0) = P(B(t_0+t) < x_0 | B(t_0) = x_0) = \frac{1}{2}.$$

这个是质点每次向左向右作等可能随机游动的直接结果.

以上我们讨论了 BM 的联合概率密度. 下面, 进一步讨论它的重要性质.

2. Brown 运动的马氏性

由 BM 是独立增量过程以及 (5.1.4) 式可得以下结论.

(1) 正向马氏性

$\forall t_1 < t_2 < \cdots < t_n$, 在给定 $B(t_1), \cdots, B(t_{n-1})$ 下, $B(t_n)$ 的条件概率密度函数与只给定 $B(t_{n-1})$ 下 $B(t_n)$ 的条件概率密度相同 (参考练习题 5.1.5).

(2) 逆向马氏性

$\forall t_1 > t_2 > \cdots > t_n$, 在给定 $B(t_1), \cdots, B(t_{n-1})$ 下, $B(t_n)$ 的条件概率密度函数与只给定 $B(t_{n-1})$ 下 $B(t_n)$ 的条件概率密度相同.

(3) 中间关于两边的马氏性

$\forall t_1 < t_2 < \cdots < t_n$ 及 $1 < i < n$, 在给定 $B(t_1), \cdots, B(t_{i-1}), B(t_{i+1}), \cdots, B(t_n)$ 下, $B(t_i)$ 的条件概率密度函数与只给定 $B(t_{i-1}), B(t_{i+1})$ 下 $B(t_i)$ 的条件概率密度相同.

特别是在给定 $B(t_1)$ 与 $B(t_3)$ 下, 去求 $B(t_2)$ 的条件概率密度, 结果会怎样呢? 先看看取 $t_1 = 0, t_3 = 1, t_2 = t, 0 < t < 1$ 的情形. 由式 (5.1.4) 知, 在 $B(0) = 0$ 下, $B(t), B(1)$ 的联合概率密度函数为:

$$f(x, y) = \frac{1}{2\pi\sqrt{t(1-t)}} \exp\left[-\frac{1}{2}\left\{\frac{x^2}{t} + \frac{(y-x)^2}{1-t}\right\}\right].$$

在 $B(0) = 0$ 下, $B(1)$ 的概率密度为 $f(y) = \frac{1}{\sqrt{2\pi}} \exp[-\frac{1}{2}y^2]$. 从而在 $B(0) = B(1) = 0$ 下, $B(t)$ 的条件概率密度为

$$f_t(x|B(0) = B(1) = 0) = \frac{1}{\sqrt{2\pi t(1-t)}} \exp\left[-\frac{1}{2} \frac{x^2}{t(1-t)}\right],$$

仍为正态分布. 可以看出

$$E[B(t)|B(0) = B(1) = 0] = 0, \quad E[B^2(t)|B(0) = B(1) = 0] = t(1-t).$$

对于更一般的情形, 我们有以下:

定理 5.1.2 对 $0 \leq t_1 < t < t_2$, 给定 $B(t_1) = a, B(t_2) = b, B(0) = 0$, 则 $B(t)$ 的条件概率密度是一正态密度, 其均值为 $a + (b-a)(t-t_1)(t_2-t_1)^{-1}$, 方差为 $(t_2-t)(t-t_1)(t_2-t_1)^{-1}$.

证 由

$$\begin{aligned}
 & E(B(t)|B(t_1)=a, B(t_2)=b) \\
 &= E[B(t) - B(t_1) + B(t_1)|B(t_1) - B(0) = a, B(t_2) - B(t_1) = b - a] \\
 &= E[B(t) - B(t_1)|B(t_2) - B(t_1) = (b-a)] + a \\
 &= \frac{(t-t_1)}{\sqrt{(t-t_1)(t_2-t_1)}} \cdot \sqrt{\frac{t-t_1}{t_2-t_1}} [(b-a) - 0] + a \\
 &= (t-t_1)(t_2-t_1)^{-1}(b-a) + a
 \end{aligned}$$

为求条件方差, 先求相应的条件 p.d.f..

$B(t_1), B(t), B(t_2)$ 的 j.p.d.f. 为

$$f(x_1, x, x_2) = \frac{1}{(2\pi)^{\frac{3}{2}} [t_1(t-t_1)(t_2-t)]^{\frac{1}{2}}} \exp\left\{-\frac{1}{2}\left[\frac{x_1^2}{t_1} + \frac{(x-x_1)^2}{(t-t_1)} + \frac{(x_2-x)^2}{(t_2-t)}\right]\right\}$$

$B(t_1), B(t_2)$ 的 j.p.d.f. 为

$$f(x_1, x_2) = \frac{1}{(2\pi)^{\frac{2}{2}} [t_1(t_2-t_1)]^{\frac{1}{2}}} \exp\left\{-\frac{1}{2}\left[\frac{x_1^2}{t_1} + \frac{(x_2-x_1)^2}{(t_2-t_1)}\right]\right\}$$

故在 $B(t_1) = a, B(t_2) = b$ 下, $B(t)$ 的条件 p.d.f 为

$$\begin{aligned}
 f_{B(t)|B(t_1)=a, B(t_2)=b}(x|a, b) &= \frac{f(x_1, x, x_2)}{f(x_1, x_2)} \Big|_{x_1=a, x_2=b} \\
 &= \frac{1}{(2\pi)^{\frac{1}{2}}} [(t-t_1)(t_2-t)(t_2-t_1)^{-1}]^{\frac{1}{2}} \\
 &\quad \exp\left\{-\frac{1}{2}\left[\frac{(x-a)^2}{t-t_1} + \frac{(b-x)^2}{t_2-t} - \frac{(b-a)^2}{t_2-t_1}\right]\right\}
 \end{aligned}$$

得: $Var(B(t)|B(t_1)=a, B(t_2)=b) = [(t-t_1)(t_2-t)(t_2-t_1)^{-1}]$

于是

$$\begin{aligned}
 f_{B(t)|B(t_1)=a, B(t_2)=b}(x|a, b) &= \frac{1}{(2\pi)^{\frac{1}{2}} [(t-t_1)(t_2-t)(t_2-t_1)^{-1}]^{\frac{1}{2}}} \cdot \\
 &\quad \exp\left\{-\frac{1}{2} \frac{[x - [(t-t_1)(t_2-t_1)^{-1}(b-a) + a]]^2}{(t-t_1)(t_2-t)(t_2-t_1)^{-1}}\right\}
 \end{aligned}$$

知 $E(B(t)|B(t_1)=a, B(t_2)=b) = a + \frac{t-t_1}{t_2-t_1}(b-a)$, $B(t)$ 在 $B(t_1)=a, B(t_2)=b$ 下的条件概率密度函数仍为正态分布. □

3. 正态过程

5.1 随机游动与 Brown 运动的定义

首先给出定义：

定义 2 随机过程 $\{X(t), t \in T\}$, 若对任意 $t_i \in T, i = 1, 2, \dots, n, X(t_1), X(t_2), \dots, X(t_n)$ 的联合分布为 n 维正态分布, 则称 $\{X(t), t \in T\}$ 为 **正态过程**. \square

由定理 5.1.1 可知 Brown 运动是正态过程. 并且有以下结论

定理 5.1.3 设 $\{B(t), t \geq 0\}$ 是正态过程, 轨道连续, $B(0) = 0, \forall s, t > 0$, 有 $E\{B(t)\} = 0, E[B(s)B(t)] = t \wedge s$, 则 $\{B(t), t \geq 0\}$ 是 BM, 反之亦然.

证明 先证充分性

由定理 5.1.1 知, 若 $B(t), t \leq 0\}$ 是 BM, 则它是正态过程. 同时由 Brown 运动定义知, $EB(t) = 0$, 且轨道连续. 设 $0 < s \leq t$, 则

$$\begin{aligned} E[B(s)B(t)] &= E[(B(t) - B(s) + B(s))B(s)] = E[(B(t) - B(s))B(s)] + E[B^2(s)] \\ &= E[B(t) - B(s)] \cdot E[B(s)] + s = s \end{aligned}$$

所以

$$E[B(s)B(t)] = s \wedge t, E[B(t)] = 0. \quad (5.1.7)$$

充分性得证.

再证必要性

当 $\{B(t), t \geq 0\}$ 是正态过程, 且满足 (5.1.7) 式时, 那么 $\forall s, t > 0$, 有

$$\begin{aligned} E[B(t) - B(s)] &= E(B(t)) - E(B(s)) = 0 \\ E[B(t) - B(s)]^2 &= E[B^2(t)] + E[B^2(s)] - 2E[B(t)B(s)] \\ &= t + s - 2(t \wedge s) = |t - s|. \end{aligned}$$

而 $\forall s_1 < t_1 \leq s_2 < t_2$, 有

$$\begin{aligned} &E[\{B(t_1) - B(s_1)\}\{B(t_2) - B(s_2)\}] \\ &= E[B(t_1)B(t_2)] - E[B(t_1)B(s_2)] - E[B(s_1)B(t_2)] + E[B(s_1)B(s_2)] \\ &= t_1 - t_1 - s_1 + s_1 = 0 \end{aligned}$$

再由正态分布知不相关即相互独立, 得: $B(t)$ 是独立增量过程. 且 $B(t) - B(s) \sim N(0, |t - s|)$, 又 $\{B(t), t \geq 0\}$ 轨道是连续的, 得 $\{B(t), t \geq 0\}$ 是 BM. 定理得证. \square

由这个定理我们就得到了判断一个正态随机过程是否为 Brown 运动的充分必要条件, 从而得出一系列很有用的结论.

定理 5.1.4 设 $\{B(t), t \geq 0\}$ 是 Brown 运动, 则

- 1° $\{B(t + \tau) - B(\tau), t \geq 0\}, \forall \tau \geq 0,$
- 2° $\{\frac{1}{\sqrt{\lambda}}B(\lambda t), t \geq 0\}, \lambda > 0,$
- 3° $\{tB(\frac{1}{t}), t \geq 0\}$, 其中 $\{tB(\frac{1}{t})\}_{t=0} \triangleq 0\}$,

4° $\{B(T=S) - B(T), 0 \leq S \leq T\}, T > 0$.

仍为 Brown 运动.

证明 证明的思路就是利用定理 5.1.3 的结论.

1° 由正态分布的性质知:

因为 $\{B(t), t \geq 0\}$ 是正态过程, 所以 $\{B(t+\tau) - B(\tau), t \geq 0\}$ 仍为正态过程, $\forall \tau > 0$, 且 $B(0+\tau) - B(\tau) = 0$.

$$\forall t > 0, E[B(t+\tau) - B(\tau)] = E[B(t+\tau)] - E[B(\tau)] = 0,$$

$$\begin{aligned} E\{[B(t+\tau) - B(\tau)][B(s+\tau) - B(\tau)]\} &= E[B(t+\tau)B(s+\tau)] - \tau - \tau + \tau \\ &= (t+\tau) \wedge (s+\tau) - \tau = s \wedge t + \tau - \tau = s \wedge t. \end{aligned}$$

满足定理 5.1.3 的条件, 所以 $\{B(t+\tau) - B(\tau), t \geq 0\}$ 是 Brown 运动.

2°, 3°, 4° 的证明与上完全类似, 不再赘述. □

至此, 我们已研究了不少 Brown 运动的重要性质和定理. 那么, 它和我们上一章重点讨论的鞅有什么关系呢? 这是一个很有价值的问题.

4. Brown 运动的鞅性

由第四章连续参数鞅的定义可得以下结论.

定理 5.1.5 设 $\{B(t), t \geq 0\}$ 为 Brown 运动, 则

$$1^\circ \{B(t), t \geq 0\}, \quad 2^\circ \{e^{\lambda B(t) - \frac{1}{2}\lambda^2 t}, t \geq 0\},$$

$$3^\circ \{B^2(t) - t, t \geq 0\}, \quad 4^\circ \{e^{i\lambda B(t) + \frac{1}{2}\lambda^2 t}, t \geq 0\}.$$

都是鞅.

证明 (略, 留作练习).

由以上结论可知, Brown 运动本身既是马氏过程, 又是连续鞅. 这个结果很别致, 但并不奇怪. 因为我们分别讨论的 Poisson 过程, Markov 链, 鞅, Brown 运动等随机过程, 不过是对一些随机过程某些方面的特殊性质进行了专门的、分类的讨论, 而并不排斥这些性质可以交叉, 可以共存于一个随机过程中. 在介绍这些概念时只能“串行”进行, 但实际上要能够“并行”应用, 融会贯通.

当然, 这个定理还给出了由 Brown 运动构造鞅的方法, 很有使用价值.

§ 5.2 Brown 运动轨道的性质

148

本节将通过以下几个命题来研究 Brown 运动轨道的性质.

以下均设 $\{B(t), t \geq 0\}$ 为标准 Brown 运动, 且 $B(0) = 0$.

5.2 Brown 运动轨道的性质

定理 5.2.1 对给定的 $t > 0$, 有

$$P(\omega : \lim_{n \rightarrow \infty} \sum_{k=1}^{2^n} (B(\frac{k}{2^n}t) - B(\frac{k-1}{2^n}t))^2 = t) = 1 \quad (5.2.1)$$

证明 $\forall t > 0$ (固定), 令 $W_{nk} = (B(\frac{k}{2^n}t) - B(\frac{k-1}{2^n}t))^2 - \frac{t}{2^n}, 1 \leq k \leq 2^n$. 则 $EW_{nk} = 0, EW_{nk}^2 = 2t^2/2^{2n}$. 由契比雪夫不等式, $\forall \epsilon > 0$

$$P\left(\sum_{k=1}^{2^n} W_{nk} > \epsilon\right) \leq \frac{2t^2}{\epsilon^2}(1/2)^n.$$

因 $\sum_{n=1}^{\infty} (1/2)^n < \infty$, 由 *Borel - Cantelli* 引理, $\forall \epsilon > 0$

$$P\left(\bigcap_{l=1}^{\infty} \bigcup_{n=l}^{\infty} \left(\sum_{k=1}^{2^n} W_{nk} > \epsilon\right)\right) = 0$$

即

$$\lim_{l \rightarrow \infty} P\left(\sup_{n \geq l} \left(\sum_{k=1}^{2^n} W_{nk} > \epsilon\right)\right) = 0$$

故

$$P(\omega : \lim_{n \rightarrow \infty} \sum_{k=1}^{2^n} (B(\frac{k}{2^n}t) - B(\frac{k-1}{2^n}t))^2 = t) = 1$$

定理得证. □

定理 5.2.2

$$P(\omega : \lim_{n \rightarrow \infty} \sum_{k=1}^{2^n} |B(\frac{k}{2^n}t) - B(\frac{k-1}{2^n}t)| = \infty) = 1 \quad (5.2.2)$$

证明 记

$$A = \{\omega : \sum_{k=1}^{2^n} (B(\frac{k}{2^n}t) - B(\frac{k-1}{2^n}t))^2 \xrightarrow{a.e.} t\},$$

$$B = \{\omega : \max_{1 \leq k \leq 2^n} \{|B(\frac{k}{2^n}t) - B(\frac{k-1}{2^n}t)|\} \rightarrow 0\},$$

$$C = \{\omega : \lim_{n \rightarrow \infty} \sum_{k=1}^{2^n} |B(\frac{k}{2^n}t) - B(\frac{k-1}{2^n}t)| = \infty\}.$$

由定理 5.2.1 知道: $P(A) = 1$; 又因 $B(t)$ 轨道以概率 1 连续, 所以可以证明极大值函数 $\max_{1 \leq k \leq 2^n} \{|B(\frac{k}{2^n}t) - B(\frac{k-1}{2^n}t)|\}$ 在闭区间 $[0, t]$ 上以概率 1 一致连续, 所以 $P(B) = 1$; 又

$$\sum_{k=1}^{2^n} (B(\frac{k}{2^n}t) - B(\frac{k-1}{2^n}t))^2 \leq \max_{1 \leq k \leq 2^n} \{|B(\frac{k}{2^n}t) - B(\frac{k-1}{2^n}t)|\} \sum_{k=1}^{2^n} |B(\frac{k}{2^n}t) - B(\frac{k-1}{2^n}t)|$$

所以

$$\sum_{k=1}^{2^n} |B(\frac{k}{2^n}t) - B(\frac{k-1}{2^n}t)| \geq \frac{\sum_{k=1}^{2^n} (B(\frac{k}{2^n}t) - B(\frac{k-1}{2^n}t))^2}{\max_{1 \leq k \leq 2^n} \{|B(\frac{k}{2^n}t) - B(\frac{k-1}{2^n}t)|\}} \quad (*)$$

当 $n \rightarrow \infty$ 时, 对任意 $\omega \in AB$,

$$\sum_{k=1}^{2^n} (B(\frac{k}{2^n}t) - B(\frac{k-1}{2^n}t))^2 \rightarrow t, \quad \max_{1 \leq k \leq 2^n} \{|B(\frac{k}{2^n}t) - B(\frac{k-1}{2^n}t)|\} \rightarrow 0$$

故由 (*) 式

$$\sum_{k=1}^{2^n} |B(\frac{k}{2^n}t) - B(\frac{k-1}{2^n}t)| \rightarrow \infty.$$

从而 $\omega \in C$, 所以 $AB \subset C$.

而 $P(A) = P(AB) + P(A\bar{B})$, $0 \leq P(A\bar{B}) \leq P(\bar{B}) = 1 - P(B) = 0$, 故 $P(AB) = P(A) = 1$. 所以 $P(C) = 1$, 从而 (5.2.2) 式成立. \square

定理 5.2.2 说明对 t 在任意区间上, 对几乎所有的 ω , Brown 运动 $B(t, \omega)$ 关于 t 不是有界变差函数.

固定 $t > 0$, 设 $0 = t_0 < t_1 < \dots < t_n = t$, 记 $\lambda = \max_{1 \leq k \leq n} (t_k - t_{k-1})$. 则有以下结论:

定理 5.2.3

$$\lim_{\lambda \rightarrow 0} \sum_{k=1}^n (B(t_k) - B(t_{k-1}))^2 \stackrel{m.s.}{=} t \quad (5.2.3)$$

证明 要证明以上命题, 只需证明 $\lim_{\lambda \rightarrow 0} E[\sum_{k=1}^n (B(t_k) - B(t_{k-1}))^2 - t]^2 = 0$. 为此计算 $E[\sum_{k=1}^n (B(t_k) - B(t_{k-1}))^2 - t]^2$.

记 $Y_k = B(t_k) - B(t_{k-1})$ ($1 \leq k \leq n$), 故 $Y_k \sim N(0, t_k - t_{k-1})$; 由正态分布的性质知 $EY_k^4 = 3 \cdot (t_k - t_{k-1})^2$, $EY_k^2 = DY_k = t_k - t_{k-1}$; 又 Y_k^2 ($1 \leq k \leq n$) 相互独立, 故当 $k \neq l$ 时, $EY_k^2 Y_l^2 = EY_k^2 EY_l^2 = (t_k - t_{k-1})(t_l - t_{l-1})$, 因此:

$$\begin{aligned} E[\sum_{k=1}^n (B(t_k) - B(t_{k-1}))^2 - t]^2 &= E[\sum_{k=1}^n Y_k^2 - t]^2 = E[(\sum_{k=1}^n Y_k^2)^2 - 2E(\sum_{k=1}^n Y_k^2)t + t^2] \\ &= 3 \cdot \sum_{k=1}^n (t_k - t_{k-1})^2 + 2 \cdot \sum_{i < j} (t_i - t_{i-1})(t_j - t_{j-1}) - 2 \cdot [\sum_{k=1}^n (t_k - t_{k-1})]t + t^2 \\ &= 2 \cdot \sum_{k=1}^n (t_k - t_{k-1})^2 \end{aligned}$$

因为 $\sum_{k=1}^n (t_k - t_{k-1})^2 \leq \lambda \cdot \sum_{k=1}^n (t_k - t_{k-1}) = \lambda t$, 所以当 $\lambda \rightarrow 0$ 时,

$$E[\sum_{k=1}^n (B(t_k) - B(t_{k-1}))^2 - t]^2 \rightarrow 0.$$

故 $\lim_{\lambda \rightarrow 0} \sum_{k=1}^n (B(t_l) - B(t_{k-1}))^2 \stackrel{m.s.}{=} t$. \square

定理 5.2.4

150

$$\lim_{\lambda \rightarrow 0} \sum_{k=1}^n B(t_{k-1})(B(t_k) - B(t_{k-1})) \stackrel{m.s.}{=} \frac{1}{2} B^2(t) - \frac{1}{2} t \quad (5.2.4)$$

5.2 Brown 运动轨道的性质

$$\lim_{\lambda \rightarrow 0} \sum_{k=1}^n B(t_k)(B(t_k) - B(t_{k-1})) \stackrel{m.s.}{=} \frac{1}{2}B^2(t) + \frac{1}{2}t \quad (5.2.5)$$

证明 令 $A_n = \sum_{k=1}^n B(t_k)(B(t_k) - B(t_{k-1}))$, $C_n = \sum_{k=1}^n B(t_{k-1})(B(t_k) - B(t_{k-1}))$ ($n \in \mathbb{N}$), 则

$$A_n + C_n = \sum_{k=1}^n (B(t_k) + B(t_{k-1}))(B(t_k) - B(t_{k-1})) = \sum_{k=1}^n (B^2(t_k) - B^2(t_{k-1})) = B^2(t)$$

由定理 5.2.3 得 $A_n - C_n = \sum_{k=1}^n (B(t_k) - B(t_{k-1}))^2 \xrightarrow{m.s.} t$ ($\lambda \rightarrow 0$). 故 $A_n = B^2(t) - C_n$, 而由均方收敛的定义知: $\lim_{\lambda \rightarrow 0} E(A_n - C_n - t)^2 = 0$, 所以 $\lim_{\lambda \rightarrow 0} E(B^2(t) - 2C_n - t)^2 = 0$, 所以 $\lim_{n \rightarrow \infty} E[C_n - (\frac{1}{2}B^2(t) - \frac{1}{2}t)]^2 = 0$. 由此可得

$$\lim_{\lambda \rightarrow 0} E[\sum_{k=1}^n B(t_{k-1})(B(t_k) - B(t_{k-1})) - (\frac{1}{2}B^2(t) - \frac{1}{2}t)]^2 = 0$$

(5.2.4) 式成立. 同理可以证明 (5.2.5). □

对定理 5.2.4 我们有更一般的形式.

定理 5.2.4a

$$\lim_{\lambda \rightarrow 0} \sum_{k=1}^n B(t_{k-1} + \theta(t_k - t_{k-1}))(B(t_k) - B(t_{k-1})) \stackrel{m.s.}{=} \frac{1}{2}B^2(t) - \frac{1}{2}(2\theta - 1)t \quad (5.2.6)$$

其中 $0 \leq \theta \leq 1$.

证明提示: $\sum_{k=1}^n B(t_{k-1} + \theta(t_k - t_{k-1}))(B(t_k) - B(t_{k-1})) = \frac{1}{2} \sum_{k=1}^n \{B^2(t_k) - B^2(t_{k-1}) + [B(t_{k-1} + \theta(t_k - t_{k-1})) - B(t_{k-1})]^2 - [B(t_k) - B(t_{k-1} + \theta(t_k - t_{k-1}))]^2\}$.

定理 5.2.5 Brown 运动 $\{B(t), t \in \mathbb{R}^+\}$, $\forall t \geq 0$, 几乎对所有轨道 ω 都没有有限的导数.

证明 先考虑 $t > 0$ 的情形.

如果 $B(t)$ 在 t 可导, 则 $\exists l \in \mathbb{R}$, 对充分大的 n , 令 $i = [nt] + 1$, 只要 $i < j \leq i + 3$ (也就是说, $-\frac{2}{n} + t \leq \frac{i-1}{n} < \frac{i}{n} \leq t + \frac{4}{n}$), 则有

$$|B(\frac{j}{n}) - B(\frac{j-1}{n})| \leq \frac{l}{n}$$

令 $D_t = \{\omega : B(t) \text{ 在 } t > 0 \text{ 可导}\}$, 则有

$$D \triangleq \bigcup_{t>0} D_t \subset \bigcup_{l \geq 1} \bigcap_{n \geq 1} \bigcup_{i=1}^{n+1} \bigcap_{j=i+1}^{151} \{|B(\frac{j}{n}) - B(\frac{j-1}{n})| \leq \frac{l}{n}\} \triangleq \Gamma.$$

$\forall l \geq 1$, 由 Brown 运动的增量独立性, 得

$$\begin{aligned} P\left(\bigcap_{j=i+1}^{i+3} \left\{|B\left(\frac{j}{n}\right) - B\left(\frac{j-1}{n}\right)| \leq \frac{l}{n}\right\}\right) &= (P(|N(0, \frac{1}{n})| \leq \frac{l}{n}))^3 \\ &= (P(|Z| \leq \frac{l}{\sqrt{n}}))^3 \\ &\leq \left(\frac{l}{\sqrt{2\pi}}\right)n^{-3/2}. \end{aligned}$$

因此

$$\lim_{n \rightarrow \infty} \sum_{i=1}^{n+1} P\left(\bigcap_{j=i+1}^{i+3} \left\{|B\left(\frac{j}{n}\right) - B\left(\frac{j-1}{n}\right)| \leq \frac{l}{n}\right\}\right) \leq \lim_{n \rightarrow \infty} 2\left(\frac{l}{\sqrt{2\pi}}\right)n^{-\frac{1}{2}} = 0.$$

所以

$$\begin{aligned} P\left(\bigcap_{n \geq 1} \bigcup_{i=1}^{n+1} \bigcap_{j=i+1}^{i+3} \left\{|B\left(\frac{j}{n}\right) - B\left(\frac{j-1}{n}\right)| \leq \frac{l}{n}\right\}\right) &\leq \lim_{n \rightarrow \infty} P\left(\bigcup_{i=1}^{n+1} \bigcap_{j=i+1}^{i+3} \left\{|B\left(\frac{j}{n}\right) - B\left(\frac{j-1}{n}\right)| \leq \frac{l}{n}\right\}\right) \\ &\leq \lim_{n \rightarrow \infty} \sum_{i=1}^{n+1} P\left(\bigcap_{j=i+1}^{i+3} \left\{|B\left(\frac{j}{n}\right) - B\left(\frac{j-1}{n}\right)| \leq \frac{l}{n}\right\}\right) \\ &= 0. \end{aligned}$$

故

$$P(D) \leq P(\Gamma) \leq \sum_{l \leq 1} P\left(\bigcap_{n \geq 1} \bigcup_{i=1}^{n+1} \bigcap_{j=i+1}^{i+3} \left\{|B\left(\frac{j}{n}\right) - B\left(\frac{j-1}{n}\right)| \leq \frac{l}{n}\right\}\right) = 0.$$

当 $t = 0$ 时, 考虑右导数, 类似可证. 至此命题得证. \square

通过以上定理, 可得 Brown 运动轨道有以下性质:

- (1) 对任意给定的小区间, 几乎对所有的轨道 $\omega, B(t)$ 关于 t 都不是有界变差函数.
- (2) 对任意的 $t \geq 0$, 几乎对所有的轨道 $\omega, B(t)$ 关于 t 都没有有限的导数.
- (3) (5.2.6) 右边和式, 当取不同的 θ 时, 其均方极限也不同.

§ 5.3 首中时与最大值 (Hitting Time and Maximarn Value)

在这一节里我们将讨论 Brown 运动中的首达时间 (首中时) 的分布及过零点概率的反正弦定理.

首先我们来看看何为首中时.

设 $\{B(t), t \geq 0\}$ 为标准 Brown 运动. 不妨设 $B(0) = 0$, 令 $T_a = \inf\{t : t > 0, B(t) = a\}$, 则 T_a 表示首次击中 a 的时间 (首中时). 要研究 $P(T_a \leq t)$ 有多大. 仍从讨论事件的等价性入手.

5.3 首中时与最大值 (Hitting Time and Maximal Value)

对 $\forall t > 0$, $M_t = \max_{0 \leq u \leq t} B(u)$, 表示 $[0, t]$ 上的最大值. 当 $a > 0$ 时, 显然存在下述事件等价关系:

$$\{T_a \leq t\} = \{M_t \geq a\}.$$

则有

$$P(T_a \leq t) = P(M_t \geq a).$$

为求 $P(T_a \leq t)$, 注意到:

$$P(B(t) \geq a) = P(B(t) \geq a | T_a \leq t)P(T_a \leq t) + P(B(t) \geq a | T_a > t)P(T_a > t)$$

显然, $P(B(t) \geq a | T_a > t) = 0$, 又由 Brown 运动的对称性知, 在 $(T_a \leq t)$ 的条件下, 即 $B(T_a) = a$ 时, $(B(t) \geq a)$ 与 $(B(t) < a)$ 是等可能的, 即:

$$P(B(t) \geq a | T_a \leq t) = P(B(t) < a | T_a \leq t) = \frac{1}{2}.$$

如图 5.1.1 所示. 故 $P(T_a \leq t) = 2P(B(t) \geq a)$.




图 5.1.1

于是, 当 $a > 0$ 时,

$$\begin{aligned} P(T_a \leq t) &= \frac{2}{\sqrt{2\pi t}} \int_a^{+\infty} e^{-\frac{u^2}{2t}} du \\ &= \sqrt{\frac{2}{\pi}} \int_{\frac{a}{\sqrt{t}}}^{+\infty} e^{-\frac{x^2}{2}} dx \\ &= 2(1 - \Phi(\frac{a}{\sqrt{t}})). \end{aligned}$$

而当 $a < 0$ 时, 由于 Brown 运动的对称性, 显然 $P(T_{-a} \leq t) = P(T_a \leq t)$, 所以对一般的 a , 有

$$P(T_a \leq t) = \frac{2}{\sqrt{2\pi}} \int_{\frac{|a|}{\sqrt{t}}}^{+\infty} e^{-\frac{u^2}{2}} du = 2(1 - \Phi(\frac{|a|}{\sqrt{t}})). \quad (5.3.1)$$

这就得到了首中时的分布.

由此可以推知两个重要的结论:

1. T_a 几乎处处有限, 即 $P(T_a < \infty) = 1$. 因 $P(T_a < \infty) = \lim_{t \rightarrow \infty} P(T_a \leq t) = \frac{2}{\sqrt{2\pi}} \int_0^{+\infty} e^{-\frac{u^2}{2}} du = 1$,

即 a 点首中时 T_a 小于无穷的概率为 1.

2. $ET_a = +\infty$. 因

$$\begin{aligned} ET_a &= \int_0^{\infty} P(T_a > t) dt \\ &= \frac{2}{\sqrt{2\pi}} \int_0^{\infty} \int_0^{\frac{|a|}{\sqrt{t}}} e^{-\frac{u^2}{2}} du dt \\ &= \frac{2}{\sqrt{2\pi}} \int_0^{\infty} \left[\int_0^{\frac{a^2}{u^2}} dt \right] e^{-\frac{u^2}{2}} du \\ &= \frac{2a^2}{\sqrt{2\pi}} \int_0^{\infty} \frac{1}{u^2} e^{-\frac{u^2}{2}} du \\ &\geq \frac{2a^2}{\sqrt{2\pi}} \int_0^1 \frac{1}{u^2} e^{-\frac{u^2}{2}} du \geq \frac{2a^2 e^{-\frac{1}{2}}}{\sqrt{2\pi}} \cdot \int_0^1 \frac{du}{u^2} = \infty \end{aligned}$$

所以有 $ET_a = \infty$, 这时多么不可思议! $P(t_a < \infty) = 1$, 而 $ET_a = \infty$, 不论 a 多么接近初态. 不过对比第三章的结论, 可以知道这与离散时间简单的对称随机游动 $ET_{0j} = \infty$, $j = 1, 2, \dots$ 是完全一致的.

以上我们对首中时进行了讨论, 下面研究一下过零点的反正弦定律.

$\forall t_1 < t_2$, 记事件 $0(t_1, t_2) = \{ \text{至少有一个 } t \in (t_1, t_2), \text{ 使 } B(t) = 0 \}$, 即在 (t_1, t_2) 内至少过一次零点. 由全概率公式有:

$$P(0(t_1, t_2)) = \int_{-\infty}^{\infty} P\{0(t_1, t_2) | B(t_1) = x\} \cdot \frac{1}{\sqrt{2\pi t_1}} e^{-\frac{x^2}{2t_1}} dx. \quad (5.3.2)$$

由 Brown 运动的连续性及对称性可知:

$$P(0(t_1, t_2) | B(t_1) = x) = P(T_x \leq t_2 - t_1).$$

如图 5.1.2 所示.




图 5.1.2

5.3 首中时与最大值 (Hitting Time and Maximal Value)

将上式及 (5.3.1) 式的结果代入 (5.3.2) 式, 便有

$$P(0(t_1, t_2)) = \frac{1}{\pi \sqrt{t_1(t_2 - t_1)}} \int_0^\infty \int_x^\infty e^{-\frac{y^2}{2(t_2 - t_1)}} dy \cdot e^{-\frac{x^2}{2t_1}} dx.$$

进一步讨论, 我们将得到下面的定理:

定理 5.3.1 记 $0(t_1, t_2) = \{ \text{在 } t \in (t_1, t_2) \text{ 内至少有一个 } t, \text{ 使 } B(t) = 0 \}$, $\bar{0}(t_1, t_2) = \{ \text{在 } t \in (t_1, t_2) \text{ 内没有一个 } t, \text{ 使 } B(t) = 0 \}$. 则

$$P\{\bar{0}(t_1, t_2)\} = \frac{2}{\pi} \arcsin \sqrt{\frac{t_1}{t_2}}.$$

且当 $t_1 = xt, t_2 = t, 0 < x < 1$ 时, 有

$$P\{\bar{0}(xt, t)\} = \frac{2}{\pi} \arcsin \sqrt{x}.$$

证明 由前述讨论已知:

$$\begin{aligned} P(0(t_1, t_2)) &= \int_{-\infty}^\infty P\{0(t_1, t_2) | B(t) = x\} \cdot \frac{1}{\sqrt{2\pi t_1}} e^{-\frac{x^2}{2t_1}} dx \\ &= \frac{1}{\pi \sqrt{t_1(t_2 - t_1)}} \int_0^\infty \int_x^\infty e^{-\frac{y^2}{2(t_2 - t_1)}} dy e^{-\frac{x^2}{2t_1}} dx. \end{aligned}$$

这个积分不易求得, 下面我们另辟蹊径. 由 $P(T_a \leq t) = \frac{2}{\sqrt{2\pi}} \int_{\frac{|a|}{\sqrt{t}}}^\infty e^{-\frac{u^2}{2}} du$, 可得 T_a 的概率密度函数 p.d.f. 为:

$$g_{T_a}(t) = \frac{dP(T_a \leq t)}{dt} = \frac{|a|}{\sqrt{2\pi}} t^{-\frac{3}{2}} e^{-\frac{a^2}{2t}}. \quad (5.3.3)$$

故 $P(T_a \leq t) = \frac{|a|}{\sqrt{2\pi}} \cdot \int_0^t u^{-\frac{3}{2}} e^{-\frac{a^2}{2u}} du$. 则

$$\begin{aligned} P(0(t_1, t_2)) &= \int_{-\infty}^\infty P(0(t_1, t_2) | B(t_1) = x) \cdot \frac{1}{\sqrt{2\pi t_1}} e^{-\frac{x^2}{2t_1}} dx \\ &= 2 \int_0^\infty P(T|x| \leq t_2 - t_1) \frac{1}{\sqrt{2\pi t_1}} e^{-\frac{x^2}{2t_1}} dx \\ &= \frac{2}{\sqrt{2\pi t_1}} \int_0^\infty \left[\frac{x}{\sqrt{2\pi}} \int_0^{t_2 - t_1} u^{-\frac{3}{2}} e^{-\frac{x^2}{2u}} du \right] e^{-\frac{x^2}{2t_1}} dx \\ &= \frac{1}{\pi \sqrt{t_1}} \int_0^{t_2 - t_1} u^{-\frac{3}{2}} \left\{ \int_0^\infty x \cdot \exp\left[-\frac{x^2}{2}\left(\frac{1}{u} + \frac{1}{t_1}\right)\right] dx \right\} du \\ &= \frac{1}{\pi \sqrt{t_1}} \int_0^{t_2 - t_1} u^{-\frac{3}{2}} \left\{ \int_0^\infty \frac{ut_1}{t_1 + u} e^{-\frac{x^2}{2}\left(\frac{1}{u} + \frac{1}{t_1}\right)} d\left[\frac{x^2}{2}\left(\frac{1}{u} + \frac{1}{t_1}\right)\right] \right\} du \\ &= \frac{1}{\pi \sqrt{t_1}} \int_0^{t_2 - t_1} u^{-\frac{3}{2}} \cdot \frac{ut_1}{t_1 + u} \left[-e^{-\frac{x^2}{2}\left(\frac{1}{u} + \frac{1}{t_1}\right)} \right]_0^\infty du \\ &= \frac{1}{\pi \sqrt{t_1}} \int_0^{t_2 - t_1} u^{-\frac{1}{2}} \cdot \frac{t_1}{t_1 + u} du. \end{aligned}$$

令 $u = t_1 v^2$, 则上式化作

$$\begin{aligned} P(0(t_1, t_2)) &= \frac{1}{\pi\sqrt{t_1}} \int_0^{h(t_1, t_2)} \frac{2t_1 v \, dv \sqrt{t_1}}{v(t_1 + t_1 v^2)} = \frac{2}{\pi} \int_0^{h(t_1, t_2)} \frac{dv}{1 + v^2} \\ &= \frac{2}{\pi} \arctan h(t_1, t_2) = \frac{2}{\pi} \arccos \sqrt{\frac{t_1}{t_2}}. \end{aligned}$$

其中 $h(t_1, t_2) = \sqrt{\frac{t_2 - t_1}{t_1}}$. 所以 $P(\bar{0}(t_1, t_2)) = 1 - P(0(t_1, t_2)) = \frac{2}{\pi} \arcsin \sqrt{\frac{t_1}{t_2}}$.

当取 $t_1 = xt$, $t_2 = t$, $0 < x < 1$ 时, 有

$$P(\bar{0}(xt, t)) = \frac{2}{\pi} \arcsin \sqrt{x}$$

上述定理得证. □

这个过零点的反正弦定律的意义就在于它揭示了上述概率仅与时间区间端点的比值 x 有关, 而与 t 无关. 这是个很耐人寻味的结果.

§ 5.4 Brown 桥 (Brown Bridge)

在许多实际问题中, 往往是在给定初始 $t = 0$ 时的 $X(0) = x$ 和过程终了 $t_0 > 0$ 时 $X(t_0) = y$ 的条件下研究中间过程的情形, 即考虑 $\{X(t), 0 \leq t \leq t_0 | X(0) = x, X(t_0) = y\}$ 的性质.

在讨论标准 Brown 运动 $\{B(t), t \geq 0\}$ 时, 设 $B(0) = 0$, 若记

$$X(t) = B(t) + x + \frac{t}{t_0} \{y - x - B(t_0)\}.$$

则过程 $\{X(t), 0 \leq t \leq t_0\}$ 的任何路径必经过 $(0, x)$ 和 (t_0, y) 两点, 就仿佛两端固定的桥梁, 因而称之为 Brown 桥. 通过坐标变换, 总可以将上述简化为:

$$X(t) = B\left(\frac{t}{t_0}\right) - \frac{t}{t_0} B(1), \quad X(0) = 0, \quad X(t_0) = 0$$

的情形. 由此引出下面的定义.

定义 1 $\{B(t), t \geq 0\}$ 为标准 Brown 运动, 不妨设 $B(0) = 0$, 令 $B_{00}(t) = B(t) - tB(1)$, 则称 $\{B_{00}(t), 0 \leq t \leq 1\}$ 为 Brown 桥 (Brown Bridge). □

Brown 桥在实际中用途很广, 下面给出它的基本性质.

定理 5.4.1 $\{B_{00}(t), 0 \leq t \leq 1\}$ 的分布与 $\{B(t), t \geq 0\}$ 在 $B(1) = 0$ 下的条件分布相同.

证明 由 Brown 运动是正态过程及正态分布的性质知, $B_{00}(t)$ 与 $\{B(t), 0 \leq t \leq 1 | B(0) = B(1) = 0\}$ 的分布均为正态分布, 故要想证明这两个分布相同, 只需证其一阶矩和二阶矩均相等即可.

5.4 Brown 桥 (Brown Bridge)

首先看一阶矩：

$$E[B_{00}(t)] = E[B(t) - tB(1)] = 0.$$

由 § 5.1 定理 5.1.2 知，当 $B(0) = 0$ 时， $E[B(t)|B(1) = 0] = 0, \forall 0 \leq t \leq 1$. 知二者的一阶矩相同. 下面讨论二阶矩.

$$\begin{aligned} E[B_{00}^2(t)] &= E[B(t) - tB(1)]^2 = E[B^2(t)] + t^2 E[B^2(1)] - 2tE[B(t)B(1)] \\ &= t + t^2 \cdot 1 - 2t \cdot t = t(1 - t). \end{aligned}$$

再利用 § 5.1 定理 5.1.2 的结论，知：

$$E[B^2(t)|B(1) = 0] = (1 - t)(t - 0)(1 - 0)^{-1} = t(1 - t).$$

显然二者的方差也相等. 那么协方差呢？ $\forall 0 \leq s, t \leq 1$,

$$\begin{aligned} Cov[B_{00}(s), B_{00}(t)] &= E[B_{00}(s)B_{00}(t)] - E[B_{00}(s)] \cdot E[B_{00}(t)] \\ &= E[B(s) - sB(1)][B(t) - tB(1)] - 0 \\ &= E[B(s)B(t)] - tE[B(s)B(1)] - sE[B(1)B(t)] + stE[B^2(1)] \\ &= s \wedge t - st - st + st. \end{aligned}$$

不妨设 $s \leq t$, 则有 $Cov(B_{00}(s), B_{00}(t)) = s(1 - t)$.

而

$$\begin{aligned} &Cov[(B(s), B(t))|B(1) = 0] \\ &= E[B(s)B(t)|B(1) = 0] - E[B(s)|B(1) = 0] \cdot E[B(t)|B(1) = 0] \\ &= E\{E[B(s)B(t)|B(t), B(1) = 0]|B(1) = 0\} - 0 \\ &= E\{B(t)E[B(s)|B(t), B(1) = 0]|B(1) = 0\} \\ &= E\{B(t)[0 + \frac{B(t)(s - 0)}{t - 0}]\big|B(1) = 0\} \\ &= E\{B^2(t) \cdot \frac{s}{t}\big|B(1) = 0\} = \frac{s}{t}E[B^2(t)|B(1) = 0] \\ &= \frac{s}{t} \frac{(1 - t)(t - 0)}{1 - 0} = s(1 - t). \end{aligned}$$

可知二者的协方差亦相等. 即二者的二阶矩均相同，又它们都是正态分布，从而得出结论，二者的分布相同. \square

值得注意的是在证明中我们曾多次用到了 § 5.1 定理 5.1.2 的结论.

有了上面这个定理，Brown 桥就和 Brown 运动建立了直接的明确的联系，它就不再显得有些神秘. 下面我们看看 Brown 桥在统计中的应用.

Brown 桥在研究经验分布函数中起着非常重要的作用. 设 $X_1, X_2, \dots, X_n, \dots$ 独立同分布, $X_n \sim U(0, 1)$, 对 $0 < s < 1$, 记

$$N_n(s) = \sum_{i=1}^n I_{(X_i \leq s)},$$

$N_n(s)$ 表示前 n 个 X_1, X_2, \dots, X_n 中取值不超过 s 的个数, 称 $F_n(s) = N_n(s)/n$ 为经验分布函数. 注意 $F_n(s)$ 是随机变量.

显然, $N_n(s) \sim B(n, s)$, 则由强大数定理, 有

$$P(\lim_{n \rightarrow \infty} F_n(s) = s) = 1.$$

即 $n \rightarrow \infty$ 时, $F_n(s)$ 以概率 1 收敛于 s . 事实上, 由 Glivenko-Cantelli 定理, 还有更强的结果. 即 $n \rightarrow \infty$ 时, $F_n(s)$ 以概率 1 一致地收敛于 s .

$$P\{\lim_{n \rightarrow \infty} (\sup_{0 < s < 1} |F_n(s) - s|) = 0\} = 1.$$

同时若令 $\alpha_n(s) = \sqrt{n}(F_n(s) - s)$.

则 $E[\alpha_n(s)] = \sqrt{n}(EF_n(s) - s) = 0$,

$$D[\alpha_n(s)] = (\sqrt{n})^2 D\left(\frac{N_n(s)}{n}\right) = n \cdot \frac{1}{n} s(1-s) = s(1-s).$$

由中心极限定理, 对任意 x :

$$\lim_{n \rightarrow \infty} P(\alpha_n(s) \leq x) = \frac{1}{\sqrt{2\pi s(1-s)}} \int_{-\infty}^x e^{-\frac{u^2}{2s(1-s)}} du.$$

这个式子似曾相识, 进一步研究会得到奇妙的结果.

再来考虑随机过程 $\{\alpha_n(s), 0 \leq s \leq 1\}$ 在 $n \rightarrow \infty$ 时的极限特性. 首先, 注意到 $\forall s < t$, 在给定 $N_n(s)$ 下 $N_n(t) - N_n(s)$ 的条件分布恰好是参数分别为 $n - N_n(s)$ 与 $(t-s)/(1-s)$ 的二项分布, 即给定 $N_n(s)$, $(N_n(t) - N_n(s))$ 的条件分布为 $B\{n - N_n(s), \frac{t-s}{1-s}\}$. 故由中心极限定理知, $\alpha_n(s)$ 与 $\alpha_n(t)$ 的联合分布, 当 $n \rightarrow \infty$ 时, 趋向二维正态分布. 类似的理由断定 $\{\alpha_n(s), 0 \leq s \leq 1\}$ 的极限过程是一正态过程. 前面已得 $E(\alpha_n(s)) = 0$, $D(\alpha_n(s)) = s(1-s)$,

故我们只需计算协方差就可以掌握其全面性质. 对 $0 \leq s \leq t \leq 1$, 有

$$\begin{aligned}
 \text{Cov}(\alpha_n(s), \alpha_n(t)) &= E[\alpha_n(s)\alpha_n(t)] - E[\alpha_n(s)]E[\alpha_n(t)] \\
 &= n \cdot E\{[F_n(s) - s][F_n(t) - t]\} - 0 \\
 &= \frac{1}{n} \cdot E[N_n(s)N_n(t)] - n \cdot tE[F_n(s)] - n \cdot sE[F_n(t)] + nst \\
 &= \frac{1}{n} \cdot E[E(N_n(s)N_n(t)|N_n(t))] - nst \\
 &= \frac{1}{n} \cdot E[N_n(t)E(N_n(s)|N_n(t))] - nst \\
 &= \frac{1}{n} \cdot E[N_n(t) \cdot \frac{s}{t}N_n(t) - nst] \\
 &= \frac{1}{n} \cdot \frac{s}{t}(nt + n(n-1)t^2) - nst \\
 &= s(1-t).
 \end{aligned}$$

则 $\{\alpha_n(s), 0 \leq s \leq 1\}$ 当 $n \rightarrow \infty$ 时, 其极限随机过程是均值为零, 协方差为 $s(1-t)$ 的正态过程, 而这正是我们前面着重研究的 Brown 桥! 真是得来全不费工夫!

以上是在 $X_1, X_2, \dots, X_n, \dots$ 为 $[0, 1]$ 上的均匀分布情形下讨论的, 它可以推广到一般分布. 设 $X_1, X_2, \dots, X_n, \dots$ 为相互独立同分布的随机变量, $F(x)$ 为其概率分布函数, 则随机变量 $F(X_i) \sim U(0, 1)$. 此时记

$$N_n(s) = \{X_1, X_2, \dots, X_n \text{ 中 } F(X_i) \leq s \text{ 的个数}\} = \sum_{i=1}^n I_{(F(X_i) \leq s)}.$$

令 $F_n(s) = N_n(s)/n$, 考虑 $\sqrt{n} \sup_x |F_n(X) - F(X)|$ 的极限分布.

设 $\alpha_n(s) = \sqrt{n}(F_n(s) - s)$.

于是 $\{\alpha_n(s), 0 \leq s \leq 1\}$ 的极限过程是 Brown 桥, 即对任意的 a , 有

$$\lim_{n \rightarrow \infty} P\{\sqrt{n} \sup_x |F_n(x) - F(x)| \leq a\} = P\{\max_{0 \leq t \leq 1} |Z(t)| \leq a\}$$

此处, $\{Z(t) = B(t) - tB(1), 0 \leq t \leq 1\}$ 为 Brown 桥.

我们对 Brown 桥已成竹在胸, 从而上述统计问题便可迎刃而解.

§ 5.5 Brown 运动的各种变形与推广

这一节我们介绍由 Brown 运动导出的各种变形及推广.

1. 在某点被吸收的 Brown 运动

设 $Z(t) = \begin{cases} B(t), & \text{当 } t < T_x \\ x, & \text{当 } t \geq T_x \end{cases}$, 其中 $T_x = \min\{t : t > 0, B(t) = x\}$.

$\{Z(t), t \geq 0\}$ 表示一旦随机过程第一次击中 x 后即被吸收停留在 x 状态. 称为在 x 点被吸收的 Brown 运动.

注意到 $Z(t)$ 是混合型随机变量. 为求 $Z(t)$ 的分布, 再次利用 Brown 运动的对称性, 不妨设 $x > 0$, 分情况讨论 $P(Z(t) \leq y)$:

当 $y > x$ 时, $P(Z(t) \leq y) = 1$,

当 $y = x$ 时, $P(Z(t) = x) = P(T_x \leq t) = \frac{2}{\sqrt{2\pi t}} \int_x^\infty e^{-\frac{u^2}{2t}} du$,

当 $y < x$ 时的情况比较复杂. 首先进行事件分解. 显然存在下列事件等价关系:

$$(Z(t) \leq y) = (B(t) \leq y, \max_{0 \leq s \leq t} B(s) < x)$$

$$\text{得 } (Z(t) \leq y) = \{B(t) \leq y\} - \{B(t) \leq y, \max_{0 \leq s \leq t} B(s) \geq x\}$$

$$\text{则 } P(Z(t) \leq y) = P\{B(t) \leq y\} - P\{B(t) \leq y, \max_{0 \leq s \leq t} B(s) \geq x\}$$

而

$$\begin{aligned} P(B(t) \leq y, \max_{0 \leq s \leq t} B(s) \geq x) &= P\{B(t) \leq y \mid \max_{0 \leq s \leq t} B(s) \geq x\} P\{\max_{0 \leq s \leq t} B(s) \geq x\} \\ &= P\{B(t) \geq 2x - y \mid \max_{0 \leq s \leq t} B(s) \geq x\} P\{\max_{0 \leq s \leq t} B(s) \geq x\}. \end{aligned}$$

上述概率相等的理由是, 事件 $(\max_{0 \leq s \leq t} B(s) \geq x) = (T_x \leq t)$, 而在 $(T_x \leq t)$ 发生的条




图 5.4.3

件下, $(B(t) \leq y)$ 发生, 当且仅当 $B(s)$ 在 $s = T_x$ 到达 x 后, 在 $(t - T_x)$ 的时间内至少下降了 $(x - y)$. 由对称性, 此事件的条件概率等于它至少上升了 $(x - y)$ 的概率. 即等于在 $(T_x \leq t)$ 发生的条件下, 事件 $(B(t) \geq 2x - y)$ 发生的条件概率. 如图 5.4.3 所示. 于是

$$\begin{aligned} P(B(t) \leq y, \max_{0 \leq s \leq t} B(s) \geq x) &= P(B(t) \geq 2x - y, \max_{0 \leq s \leq t} B(s) \geq x) \\ &= P(B(t) \geq 2x - y). \end{aligned}$$

所以

$$\begin{aligned} P(Z(t) \leq y) &= P(B(t) \leq y) - P(B(t) \geq 2x - y) \\ &= P(B(t) \leq y) - P(B(t) \leq y - 2x) = \frac{1}{\sqrt{2\pi t}} \int_{y-2x}^y e^{-\frac{u^2}{2t}} du. \end{aligned}$$

可见对于不易求得的概率分布可以通过事件分解和分析来逐步解决.

至此, 我们已得出在 x 点吸收的 Brown 运动的概率分布为:

$$\begin{cases} P(Z(t) \leq y) = 1, & \text{当 } y > x, \\ P(Z(t) = x) = \frac{2}{\sqrt{2\pi t}} \int_x^\infty e^{-\frac{u^2}{2t}} du, & \text{当 } y = x, \\ P(Z(t) \leq y) = \frac{1}{\sqrt{2\pi t}} \int_{y-2x}^y e^{-\frac{u^2}{2t}} du, & \text{当 } y < x. \end{cases}$$

2、在起点反射的 Brown 运动

令 $Y(t) = |B(t)|$, 则称 $\{Y(t), t \geq 0\}$ 为在起点反射的 Brown 运动. 我们研究其分布律 $P(Y(t) \leq y)$ 为多少. 显然, 当 $y < 0$ 时,

$$P(Y(t) \leq y) = 0$$

当 $y > 0$ 时,

$$\begin{aligned} P(Y(t) \leq y) &= P(|B(t)| \leq y) = P(-y \leq B(t) \leq y) \\ &= 2P(B(t) \leq y) - 1 = \frac{2}{\sqrt{2\pi t}} \int_{-\infty}^y e^{-\frac{u^2}{2t}} du - 1. \end{aligned}$$

这样就得到了它的分布.

3、几何 Brown 运动

令 $W(t) = e^{B(t)}$, 则称 $\{W(t), t \geq 0\}$ 为几何 Brown 运动.

几何 Brown 运动有时可以作为相对变化为独立同分布情况的模型. 例如, 设 $Y_{(n)}$ 是 n 时刻商品的价格, $\frac{Y_{(n)}}{Y_{(n-1)}} = X_{(n)} (n \geq 1)$ 是独立同分布的. 如取 $Y_{(0)} = 1$, $Y_{(n)} = X_{(1)} \cdot X_{(2)} \cdots X_{(n)}$, $\ln Y_{(n)} = \sum_{i=1}^n \ln X_{(i)}$. 则当 $n \rightarrow \infty$ 时, 根据中心极限定理知, $\{\ln Y_{(n)}, n \geq 1\}$ 渐近为 Brown 运动. 于是 $\{Y_{(n)}, n \geq 0\}$ 就近似为几何 Brown 运动.

取 $B(t)$ 的矩母函数 $\phi(s) = E[e^{sB(t)}]$, 则

$$\phi(s) = E[e^{sB(t)}] = \int_{-\infty}^{\infty} e^{sx} \frac{1}{\sqrt{2\pi t}} e^{-x^2/2t} dx = e^{ts^2/2}$$

相应地 $E[W(t)] = E(e^{B(t)}) = \phi(1) = e^{\frac{t}{2}}$.

$$\begin{aligned} D(W(t)) &= E[W^2(t)] - [E(W(t))]^2 = E(e^{2B(t)}) - e^t \\ &= \phi(2) - e^t = e^{2t} - e^t. \end{aligned}$$

这样就得到了几何 Brown 运动的一阶矩和二阶矩.

4、Brown 运动的积分

令 $S(t) = \int_0^t B(u) du$, 称 $\{S(t), t \geq 0\}$ 为 Brown 运动的积分.

由正态分布的性质知, $\{S(t), t \geq 0\}$ 为正态过程. 于是讨论它的性质就只需研究它的期望和协方差, 不过在讨论之前, 需要先引入一个预备定理.

定理 5.5.1 若对随机过程 $\{X(t), t \geq 0\}$ 满足 $E|X(t)| < \infty$, $DX(t) < \infty$, 则有

$$E\left[\int_0^t X(s) ds\right] = \int_0^t E[X(s)] ds,$$

$$E\left[\int_0^s \int_0^t X(v)X(u) du dv\right] = \int_0^s \int_0^t E[X(v)X(u)] du dv.$$

证明 利用 Fubini 定理即得. □

于是利用定理 5.5.1 有

$$E(S(t)) = E\left[\int_0^t B(u) du\right] = \int_0^t E[B(u)] du = 0.$$

$\forall 0 \leq \delta \leq t$, 有

$$\begin{aligned} Cov[S(\delta), S(t)] &= E\left[\int_0^\delta \int_0^t B(u)B(v) du dv\right] = \int_0^\delta \int_0^t E[B(u)B(v)] du dv \\ &= \int_0^\delta \int_0^t (u \wedge v) du dv = \int_0^\delta \left[\int_0^v u du + \int_v^t v du\right] dv \\ &= \int_0^\delta \left\{\frac{v^2}{2} + v(t-v)\right\} dv \\ &= \frac{\delta^2}{2}\left(t - \frac{\delta}{3}\right). \end{aligned}$$

这样, $\{S(t), t \geq 0\}$ 就完全地被刻画出来了.

在商业中, 若我们设 $S(t)$ 为 t 的价格, 则 $\frac{dS(s)}{dt} = B(t)$ 为价格变化率, 而它通常是遵循 Brown 运动的, 这时一个很有意思的事实, 在实际中有不少应用.

5、Brown 运动的形式导数

设 $\{B(t), t \geq 0\}$ 为 Brown 运动, 考虑增量之比, 固定 $\Delta t > 0$, 令 $\frac{B(t+\Delta t)-B(t)}{\Delta t} \triangleq \frac{\Delta B(t)}{\Delta t}$, 显然 $\{\frac{\Delta B(t)}{\Delta t}, t \geq 0\}$ 是一正态过程, 易知其一阶、二阶矩为:

$$E\left\{\frac{\Delta B(t)}{\Delta t}\right\} = \frac{E[B(t+\Delta t)] - E[B(t)]}{\Delta t} = 0.$$

$$D\left\{\frac{\Delta B(t)}{\Delta t}\right\} = \frac{1}{\Delta t^2} D[B(t+\Delta t) - B(t)] = \frac{1}{\Delta t^2} (t+\Delta t - t) = \frac{1}{\Delta t}.$$

故 $\frac{\Delta B(t)}{\Delta t} \sim N(0, \frac{1}{\Delta t})$.

再考虑其协方差, 设 $0 \leq s < t$, 取 Δt 充分小, 使 $s < s + \Delta t < t$, 于是有:

$$Cov\left(\frac{\Delta B(s)}{\Delta t}, \frac{\Delta B(t)}{\Delta t}\right) = E\left[\frac{\Delta B(s)}{\Delta t} \cdot \frac{\Delta B(t)}{\Delta t}\right] - E\left\{\frac{\Delta B(s)}{\Delta t}\right\} \cdot E\left\{\frac{\Delta B(t)}{\Delta t}\right\} = 0$$

可见 $s \neq t$ 且当 Δt 充分小时, $\frac{\Delta B(s)}{\Delta t}$ 与 $\frac{\Delta B(t)}{\Delta t}$ 相互独立.

进一步讨论, 当 $\Delta t \rightarrow 0^+$ 时, $E(\frac{\Delta B(t)}{\Delta t}) = 0$, $D(\frac{\Delta B(t)}{\Delta t}) \rightarrow \infty$, 因此我们把 $\Delta t \rightarrow 0$ 时, 正态过程 $\{\frac{\Delta B(t)}{\Delta t}, t \geq 0\}$ 的极限过程形式上记为 $\{\frac{dB(t)}{dt}, t \geq 0\}$, 定义如下:

5.6 带有漂移的 Brown 运动

称 $\{\frac{dB(t)}{dt}, t \geq 0\}$ 为 Brown 运动的形式导数, 若

1° $\forall t \geq 0, \frac{dB(t)}{dt} \sim N(0, \infty)$

2° $\forall t_1 \neq t_2, \frac{dB(t)}{dt}|_{t=t_1}$ 与 $\frac{dB(t)}{dt}|_{t=t_2}$ 相互独立.

Brown 运动的形式导数, 有时亦称为连续参数的白噪声. 它在物理上有许多应用, 在随机微分方程理论中也起着极其重要的作用.

§ 5.6 带有漂移的 Brown 运动 (Brown Motion With Drift)

这是一类很重要的随机过程, 先看看它的定义.

定义 1 设 $\{B(t), t \geq 0\}$ 为 Brown 运动, 记 $X(t) = B(t) + \mu t$, μ 为常数, 称 $\{X(t), t \geq 0\}$ 是带有漂移系数为 μ 的 Brown 运动. □

带有漂移的 Brown 运动的背景是一个质点在直线上作非对称的随机游动. 它具有一定的趋向, 于不规则微观运动中又有一定的宏观规则运动存在, 如分子热扩散、电子不规则运动等. 确切叙述如下:

一质点在直线上每经 Δt 随机地移动 Δx , 每次向右移 Δx 的概率为 p , 向左移 $-\Delta x$ 的概率为 q , 且每次移动相互独立, 以 $X(t)$ 表示 t 时刻质点位置. 令

$$X_i = \begin{cases} 1, & \text{第 } i \text{ 次向右移} \\ -1, & \text{第 } i \text{ 次向左移.} \end{cases}$$

则 $X(t) = (\Delta x)(X_1 + X_2 + \cdots + X_{[\frac{t}{\Delta t}]})$.

设 $\Delta x = \sqrt{\Delta t}$, $p = \frac{1}{2}(1 + \mu\sqrt{\Delta t})$, $q = \frac{1}{2}(1 - \mu\sqrt{\Delta t})$, 对给定的 μ , 取充分小的 Δt , 使 $\mu\sqrt{\Delta t} < 1$, 当 $\Delta t \rightarrow 0$ 时

$$\begin{aligned} E[X(t)] &= (\Delta x) \left[\frac{t}{\Delta t} \right] (p - q) \\ &= \sqrt{\Delta t} \cdot \left[\frac{t}{\Delta t} \right] \cdot \mu \sqrt{\Delta t} \\ &\rightarrow \mu t. \end{aligned}$$

$$\begin{aligned} D[X(t)] &= (\Delta x)^2 \left[\frac{t}{\Delta t} \right] [EX_i^2 - (EX_i)^2] \\ &= (\sqrt{\Delta t})^2 \left[\frac{t}{\Delta t} \right] [1 - (p - q)^2] \\ &= \Delta t \left[\frac{t}{\Delta t} \right] [1 - (2p - 1)^2] \\ &\rightarrow t. \quad (\Delta t \rightarrow 0) \end{aligned}$$

163

所以 $X(t) \sim N(\mu t, t)$. 可见它和 $\{B(t), t \geq 0\}$ 都是正态过程, 只是均值不为零. 这是由其不对称性引起的. μ 表示单位时间内质点漂移的平均值.

在进一步研究带漂移的 Brown 运动的重要性质之前, 先证明一个重要的预备定理.

定理 5.6.1 设 $\{B(t), t \geq 0\}$ 为 Brown 运动, 令 $X(t) = B(t) + \mu t$, $T_a = \min\{t : t > 0, X(t) = a\}$. $X(0) = x$, $x \neq a$. 则当 $h > 0$ 充分小时,

$$P(T_a \leq h | X(0) = x) = o(h).$$

证明 不妨先设 $x < a$, 证明的思路是利用有关的 Brown 运动的结论. 易知

$$P(T_a \leq h | X(0) = x) = P(T_{a-x} \leq h | X(0) = 0) \triangleq P_0(T_{a-x} \leq h)$$

取 h 满足 $0 < h < \frac{a-x}{|\mu|}$, 则 $a-x-|\mu|h > 0$.

则有

$$P_0(T_{a-x} \leq h) = P_0(\max_{0 \leq s \leq h} X(s) \geq a-x) = P_0(\max_{0 \leq s \leq h} [B(s) + \mu s] \geq a-x).$$

由于存在下列事件包含关系:

$$\{\max_{0 \leq s \leq h} (B(s) + \mu s) \geq a-x\} \subset \{\max_{0 \leq s \leq h} B(s) \geq a-x-|\mu|h\},$$

故

$$\begin{aligned} P_0(T_{a-x} \leq h) &\leq P_0\{\max_{0 \leq s \leq h} B(s) \geq a-x-|\mu|h\} = P_0(T_{a-x-|\mu|h} \leq h) \\ &\leq 2P_0\{|B(h)| \geq a-x-|\mu|h\} \\ &= 2 \cdot \frac{1}{\sqrt{2\pi h}} \int_{|y| \geq a-x-|\mu|h} e^{-y^2/2h} dy \\ &\leq \frac{2}{\sqrt{2\pi h}} \int_{-\infty}^{\infty} \frac{y^4}{(a-x-|\mu|h)^4} e^{-y^2/2h} dy \\ &= \frac{2}{(a-x-|\mu|h)^4} \int_{-\infty}^{\infty} \frac{1}{\sqrt{2\pi h}} y^4 e^{-y^2/2h} dy \\ &= \frac{2}{(a-x-|\mu|h)^4} \cdot 3h^2. \end{aligned}$$

所以有

$$P(T_a \leq h | X(0) = x) \leq \frac{6h^2}{(a-x-|\mu|h)^4} = o(h). \quad (5.6.1)$$

注意证明中用到了 $\int_{-\infty}^{\infty} \frac{y^4}{\sqrt{2\pi h}} \cdot e^{-y^2/2h} dy = 3h^2$, 即求 $N(0, h)$ 正态分布的四阶矩为 $3h^2$.

当 $a < x$ 时, 证明方法完全类似, 不再赘述. □

有了上面的定理, 就可以介绍带漂移 Brown 运动的一个有趣而重要的结论.

定理 5.6.2 设 $\{X(t) = B(t) + \mu t, t \geq 0\}$ 是漂移系数为 μ 的 Brown 运动. 对 $a, b > 0$, $-b < x < a$, $T_a = \min\{t : t > 0, X(t) = a\}$, $T_{-b} = \min\{t : t > 0, X(t) = -b\}$, 有

$$f(x) = P(T_a < T_{-b} < \infty | X(0) = x) = \frac{e^{2\mu b} - e^{-2\mu x}}{e^{2\mu b} - e^{-2\mu a}} \quad (5.6.2)$$

5.6 带有漂移的 Brown 运动

证明 证明的思路是用微分方程的方法求解, 因为上述 (5.6.2) 式显然不易由演绎推导得出. 所以首先建立 $f(x)$ 满足的微分方程 $2\mu f'(x) + f''(x) = 0$, 然后通过求解此方程, 得出 (5.6.2) 式.

仍从事件分解入手, 利用定理 5.6.1 和 Brown 运动的性质, 记 $C = \{T_a < T_{-b} < \infty\}$, $B = (T_a > h, T_b > h)$, $h > 0$, 且充分小, $X(h) - x = Y$.

则 $B^c = \{T_a \leq h\} \cup \{T_{-b} \leq h\}$.

于是 $P(B^c|X(0) = x) \leq P(T_a < h|X(0) = x) + P(T_{-b} \leq h|X(0) = x) = o(h)$.

注意这里用到了定理 5.6.1 的结论. 所以 $P(B|X(0) = x) = 1 - o(h)$. 可知

$$\begin{aligned} f(x) &= P(C|X(0) = x) \\ &= P(B|X(0) = x) \cdot P(C|X(0) = x, B) + P(B^c|X(0) = x)P(C|X(0) = x, B^c) \\ &= (1 - o(h))P\{C|X(0) = x, B\} + o(h) \\ &= P\{C|X(0) = x, \min_{0 \leq s \leq h} X(s) > -b, \max_{0 \leq s \leq h} X(s) < a\} + o(h) \\ &= E\{P\{T_a < T_{-b} < +\infty|X(0) = x, \min_{0 \leq s \leq h} X(s) > -b, \max_{0 \leq s \leq h} X(s) < a, X(h)\}\} + o(h). \end{aligned}$$

令 $X'(t) = X(h+t)$, $T'_a = \min\{t : t > 0, X'(t) = a\}$, $T'_{-b} = \min\{t : t > 0, X'(t) = -b\}$.

显然, 在 $B = \{T_a > h, T_{-b} > h\}$ 发生的情况下,

$$T_a = h + T'_a, \quad T_{-b} = h + T'_{-b}.$$

故 $f(x) = E\{P\{h + T'_a < h + T'_{-b} < \infty|X(0) = x, \min_{0 \leq s \leq h} X(s) > -b,$

$$\max_{0 \leq s \leq h} X(s) < a, X(h)\}\} + o(h).$$

利用 Brown 运动的马氏性, 有

$$\begin{aligned} f(x) &= E\{P\{T'_a < T'_{-b} < \infty|X(h)\}\} + o(h) \\ &= E\{P\{T'_a < T'_{-b} < \infty|x + Y\}\} + o(h) \\ &= E\{f(x + Y)\} + o(h). \end{aligned}$$

定理证到这里已是胜利在望.

设 $f(x)$ 在 x 点及附近有任意阶导数存在. 则有

$$f(x + Y) = f(x) + f'(x)Y + \frac{f''(x)}{2!}Y^2 + \frac{f'''(x)}{3!} + \dots$$

$$EY = E[X(h)] - x = \mu h + x - x = \mu h$$

$$EY^2 = E[X(h) - x]^2 = E[B(h) + \mu h - x]^2 = \mu^2 h^2 + h.$$

因 $Y \sim N(\mu h, h)$.

知 $EY^k = o(h)$, 当 $k \geq 3$ 时.

所以

$$\begin{aligned}
 f(x) &= E\{f(x+Y)\} + o(h) \\
 &= E\left\{f(x) + \frac{f'(x)}{1!}Y + \frac{f''(x)}{2!}Y^2 + \cdots\right\} + o(h) \\
 &= f(x) + f'(x)EY + f''(x)\frac{EY^2}{2} + \cdots + o(h) \\
 &= f(x) + \mu hf'(x) + \frac{(\mu^2 h^2 + h)}{2}f''(x) + o(h) \\
 &= f(x) + \mu hf'(x) + \frac{h}{2}f''(x) + o(h).
 \end{aligned}$$

于是

$$\mu f'(x) + \frac{1}{2}f''(x) + \frac{o(h)}{h} = 0,$$

令 $h \rightarrow 0$, 得

$$2\mu f'(x) + f''(x) = 0.$$

这就得到了我们所要寻找的那个关键的微分方程, 加上边界条件: $x = a$ 时, $f(a) = 1$; $x = -b$ 时, $f(b) = 0$, 于是有

$$\begin{cases} 2\mu f'(x) + f''(x) = 0 \\ f(a) = 1, f(-b) = 0. \end{cases} \quad (5.6.3)$$

为解此微分方程, 两边积分, 得

$$2\mu f(x) + f'(x) = C_1,$$

两边同乘 $e^{2\mu x}$, 有

$$\frac{d(e^{2\mu x} f(x))}{dx} = C_1 e^{2\mu x},$$

再积分得

$$e^{2\mu x} f(x) = C_1 e^{2\mu x} + C_2, \quad \text{即 } f(x) = C_1 + C_2 e^{-2\mu x}$$

以 $f(a) = 1, f(-b) = 0$ 边界条件代入, 得方程组

$$\begin{cases} C_1 + C_2 e^{-2\mu a} = 1 \\ C_1 + C_2 e^{2\mu b} = 0. \end{cases}$$

解之, 得 $C_1 = \frac{e^{2\mu b}}{e^{2\mu b} - e^{-2\mu a}}, C_2 = \frac{-1}{e^{2\mu b} - e^{-2\mu a}}.$

于是 $f(x) = \frac{e^{2\mu b} - e^{-2\mu x}}{e^{2\mu b} - e^{-2\mu a}}$, 可知 $f(x)$ 在 x 及附近确有任何阶导数. \square

这个定理的证明是很巧妙的, 其中利用了许多概率论和数学分析里的技巧, 非常值得玩味. 下面再给出一种运用连续鞅停时定理的证明方法.

5.6 带有漂移的 Brown 运动

证法 2 首先假设 $X(0) = 0$.

记 $T_{ab} = \inf \{t \geq 0; X(t) = a \text{ 或 } X(t) = b\}$, 并且令 $T \wedge n = \min \{T, n\}$, $T = T_{a(-b)}$. 因为 $B(t) = X(t) - \mu t, t \geq 0$ 是鞅, 又易知 $T \wedge n$ ($n \geq 1$) 关于 $B(t)$ 是停时, 且 $P(T \wedge n < \infty) = 1$, 故由停时定理, 有

$$0 = E[B(0)] = E[B(T \wedge n)] = E[X(T \wedge n)] - \mu E[T \wedge n]$$

所以 $E[T \wedge n] \leq \frac{1}{\mu} E[X(T \wedge n)] \leq \frac{1}{\mu} (a + b) < \infty$. 即, $\forall n \geq 1$, 有 $E[T \wedge n] \leq \frac{1}{\mu} (a + b) < \infty$. 又 $\forall n \geq 1, T \wedge n \leq T \wedge (n + 1)$, 由单调收敛定理, 有

$$E(T) = \lim_{n \rightarrow \infty} E(T \wedge n) \leq \frac{1}{\mu} (a + b) < \infty.$$

从而 $P(T < \infty) = 1$.

令 $V(t) = \exp \{-2\mu X(t)\}$, 易证 $V(t)$ 是鞅. 由连续鞅停时定理, 有

$$E[V(T_{a(-b)})] = E[V(0)] = 1.$$

则 $1 = P(X(T_{a(-b)}) = a) \cdot \exp \{-2\mu a\} + P(X(T_{a(-b)}) = -b) \cdot \exp \{-2\mu(-b)\}$. 所以

$$P(X(T_{a(-b)}) = a) = \frac{1 - \exp \{2\mu b\}}{\exp \{-2\mu a\} - \exp \{2\mu b\}}$$

又因为

$$\begin{aligned} P(T_a < T_{-b} < \infty | X(0) = x) &= P(X(T_{a(-b)}) = a | X(0) = x) \\ &= P(X(T_{(a-x)(-b-x)}) = a - x). \end{aligned}$$

所以

$$\begin{aligned} P(T_a < T_{-b} < \infty | X(0) = x) &= \frac{1 - \exp \{2\mu(b+x)\}}{\exp \{-2\mu(a-x)\} - \exp \{2\mu(b+x)\}} \\ &= \frac{\exp \{2\mu b\} - \exp \{-2\mu x\}}{\exp \{2\mu b\} - \exp \{-2\mu a\}} \end{aligned}$$

从而 (5.6.2) 式得证. □

此定理的结论很“绝”, 应用很广. 下面给出此定理的一个常用的推论.

推论 1 设 $\{X(t), t \geq 0\}$ 为带漂移的 Brown 运动, $X(t) = B(t) + \mu t$, 若 $\mu < 0$, 则

$$P\left\{\max_{0 \leq t < \infty} X(t) \geq a | X(0) = 0\right\} = e^{2\mu a},$$

即当 $\mu < 0$ 时, $M = \max_{0 \leq t < \infty} X(t)$ 服从参数为 2μ 的指数分布.

证明 由式 (5.6.2), 令 $b \rightarrow \infty, X(0) = 0$, 即有

$$P(T_a < \infty | X(0) = 0) = P\left(\max_{0 \leq t \leq \infty} X(t) \geq a | X(0) = 0\right) = e^{2\mu a}. \quad \square$$

在实际中,有时这个推论较原定理应用起来更为方便.

将带漂移的 Brown 运动的定义写成微分形式,得 $dX(t) = dB(t) + \mu dt$, 即质点 t 时刻位移的增量分解为随机性增量与确定性增量之和. 一般地,有如下推广: $dX(t) = \delta dB(t) + \mu dt$. 若扩散系数 δ 与漂移系数 μ 不是常数,而是 t 与 $X(t)$ 的函数,那么有如下更一般的随机微分方程:

$$dX(t) = \delta(t, X(t)) dB(t) + \mu(t, X(t)) dt$$

这类随机微分方程可用以描述分子的热运动;电子的迁移运动规律等. 例如,以 $X(t)$ 描述一个粒子在液体表面 t 时刻的速度,有

$$m \frac{dX(t)}{dt} = -fX(t) + \frac{dB(t)}{dt}.$$

其中 m 为质点质量, $-fX(t)$ 为粒子与液面的摩擦阻力,而 $\frac{dB(t)}{dt}$ 为由分子撞击产生的总的合力. 求解这一类随机微分方程在物理学工程中是常见的,而这离不开 Brown 运动的理论.

可见研究带漂移的 Brown 运动很具有实际意义,只要赋予相应系数以物理意义,就可以用它来刻划许多复杂的难以研究的物理过程,工程及经济现象.

下面诸例均采用微分方法求解. 运用连续鞅停时定理的方法,这里不再给出,留给读者作为练习.

例 1 控制生产过程的优化

考虑一个不断恶化的生产过程. 设该过程可用一个具有漂移系数为 μ 的 Brown 运动来描述. 当过程的状态为 $b(b > 0)$ 时,过程损坏而失败. 此时必须花费 R 元才能使过程回到良好状态 0 . 另外,我们可以在过程失效状态 b 之前采取预防性的维修. 若在状态 $x(x < b)$ 采取了预防性维修(或某种调整),设这一尝试成功(即回到状态 0)的概率为 α_x ,而失败(即仍转为 b 状态)的概率为 $1 - \alpha_x$. 一次维修的尝试费用为 C (与 x 无关). 我们的问题是如何寻找使得在单位平均回程时间的平均费用最小的维修策略.

先考虑当过程状态为 $x(0 < x < b)$ 时预防性维修的策略,显然,每次回到状态 0 构成一更新过程. 因此由更新过程的有关定理(见第二章 § 2.10),其单位时间平均费用为:

$$\frac{E\{\text{一个更新周期的花费}\}}{E\{\text{更新周期长度}\}} = \frac{C + R(1 - \alpha_x)}{E(\text{到达 } x \text{ 的时间})} \quad (5.6.4)$$

记 $f(x) = E\{\text{从 } 0 \text{ 出发到达 } x \text{ 的时间}\}$, 考虑充分小的 $h > 0$, 令 $Y = X(h) - X(0)$, $f(x - Y) = E\{\text{从 } 0 \text{ 出发到达 } x - Y \text{ 的时间}\} = E\{\text{从 } X(h) = Y \text{ 出发到达 } x \text{ 的时间}\}$, 则类似于上面定理 5.6.2 中的方法,有

$$f(x) = h + E[f(x - Y)] + o(h) \quad (5.6.5)$$

其中 $o(h)$ 表示在 h 之前已到达 x 的概率.

5.6 带有漂移的 Brown 运动

$$\begin{aligned} \text{由 } E[f(X(h))] &= E(f(x - Y)) = E[f(x) - f'(x)Y + \frac{1}{2!}f''(x)Y^2 \cdots] \\ &= f(x) - \mu h f'(x) + \frac{1}{2}h f''(x) - \cdots. \end{aligned}$$

由式 (5.6.5) 式 $Ef(x - Y) = f(x) - h - o(h)$,

于是

$$1 = \mu f'(x) - \frac{1}{2}f''(x) + \frac{o(h)}{h}.$$

令 $h \rightarrow 0$, 得

$$1 = \mu f'(x) - \frac{1}{2}f''(x). \quad (5.6.6)$$

与定理 5.6.2 中求解方法不同的是我们不直接解上式, 但注意到, $\forall x, y > 0$,

$$\begin{aligned} f(x+y) &= E\{\text{从 } 0 \text{ 到 } x+y \text{ 的时间}\} \\ &= E\{\text{从 } 0 \text{ 到 } x \text{ 的时间}\} + E\{\text{从 } x \text{ 到 } x+y \text{ 的时间}\} \\ &= E\{\text{从 } 0 \text{ 到 } x \text{ 的时间}\} + E\{\text{从 } 0 \text{ 到 } y \text{ 的时间}\} \\ &= f(x) + f(y). \end{aligned}$$

故 $f(x) = Cx$, $f'(x) = C$.

由 (5.6.6) 式 $f'(x)\mu = 1$, 得 $C = \frac{1}{\mu}$, 故 $f(x) = \frac{x}{\mu}$.

所以, 由式 (5.6.4), 在状态 $x(0 < x < b)$ 采取维修策略的单位时间平均费用为 $\frac{\mu[C + R(1 - \alpha_x)]}{x}$, 而不采取维修策略的单位时间平均费用为 $\frac{R\mu}{b}$. 对于给定的函数 α_x , 我们能够用微积分的办法来确定使长期运行的单位时间平均费用达最小的策略.

例 2 带漂移布朗运动在经济领域应用.

自九十年代后, 出现了研究倒向参数随机微分方程 (Backward Stochastic Differential Equation) 的理论问题, 简称 BSDE 问题. 设随机过程 $X = \{X(t), 0 \leq t \leq T\}$ 满足下列方程:

$$dX(t) = f(t, X(t))dt + g(t, X(t))dB(t), \quad \forall 0 \leq t \leq T.$$

$$X(T) = \xi.$$

显然, 上式是一般的带漂移布朗运动的微分形式. BSDE 在经济领域有重要应用, 著名经济学家 D.Duffie 和 L.Epstein 首先发现 BSDE 可以描述市场经济环境下的消费偏好. E.Ikaroui 和 Quenez 发现金融市场的许多重要派生证券的理论价格可以用 BSDE 来求解. 下面举一简单的例子.

设一个自融资且无消费的单身汉 (例如无牵挂、无负担又节约的单身汉), T 为他成家的日期, 他在 $[0, T]$ 期间的决策是: 在 t 时刻将他财产 $X(t)$ 之中的 $Y(t)$ 用于买股票, $X(t) - Y(t)$ 用于买债券, 则他的财产 $X(t), 0 \leq t \leq T$ 满足:

$$dX(t) = f(X(t), Y(t))dt - Y(t)dB(t).$$

其中 $f(X(t), Y(t)) = rX(t) + (b-r)Y(t) + (R-r)(X(t) - Y(t))$, $r > 0$ 为债券利率, R 是市场贷款利率. 一般 $R > r$, 当 $R = r$ 时, $f(x, y) = rx + (b-r)y$. 若他计划在 T 时结婚, 自己的财产要达到 ξ 元, 问他在 $[0, T]$ 内应如何作出投资决策 $\{Y(t), 0 \leq t \leq T\}$ 才能达到自己的目标: $X(t) = \xi$?

这个决策问题可化为求解下列 BSDE 问题:

$$\begin{cases} dX(t) = f(X(t), Y(t)) dt - Y(t) dB(t) \\ X(T) = \xi \end{cases}$$

的解 $\{(X(t), Y(t)), 0 \leq t \leq T\}$, 其中 $\{B(t), t \geq 0\}$ 为标准 B.M.. 上面随机微分方程的解法将在后面的第七章讨论.

以上只是带漂移 Brown 运动应用的两个实例, 它的众多应用, 我们将在以后的工作和研究中自然会遇到.

随机微分方程求解后, 可以进而求出带漂移布朗运动 $X(t)$ 的期望、协方差等随机性质. 下面介绍 Ornstein-Uhlenbeck 过程的期望、协方差的求解.

例 3 满足随机微分方程 $dX(t) = -\alpha X(t) dt + \delta dB(t)$ ($\alpha > 0$) 的随机过程 $\{X(t), t \geq 0\}$ 叫作 Ornstein-Uhlenbeck 过程. 解上面的随机微分方程 (解法在第七章讨论), 得 $X(t) = e^{-\alpha t} X(0) + \delta \int_0^t e^{-\alpha(t-u)} dB(u)$, 设 $X(0) = x$, 则 $EX(t) = xe^{-\alpha t}$. 设 $\tau > 0$,

$$\begin{aligned} Cov(X(t), X(t+\tau)) &= E(X(t)X(t+\tau)) - E(X(t))E(X(t+\tau)) \\ &= E \left[\delta^2 \left(\int_0^t \int_0^{t+\tau} e^{-\alpha(t-u)} e^{-\alpha(t+\tau-v)} dB(u) dB(v) \right) \right] \\ &= \delta^2 e^{-\alpha\tau-2\alpha t} E \left[\int_0^t \int_0^{t+\tau} e^{\alpha u} e^{\alpha v} dB(u) dB(v) \right] \\ &= \delta^2 e^{-\alpha(2t+\tau)} \int_0^t \int_0^{t+\tau} e^{\alpha(u+v)} E(dB(u) dB(v)) \end{aligned}$$

其中,

$$E[dB(u) dB(v)] = \begin{cases} 0 : & u \neq v, dB(u) \text{ 与 } dB(v) \text{ 独立.} \\ dv : & u = v, \text{ 为方差, 等于区间长度.} \end{cases} = \delta(u-v) dv.$$

从而, 原式 $= \delta^2 e^{-\alpha(2t+\tau)} \int_0^t e^{2\alpha u} du = \delta^2 / 2\alpha \cdot (1 - e^{-2\alpha t}) e^{-\alpha\tau}$.

§ 5.7 n 维 Brown 运动与牛顿位势

定义 1 $\{X(t) = (X_1(t), X_2(t), \dots, X_n(t)), t \geq 0\}$ 是取值为 \mathbb{R}^n 的随机过程, 若满足:

5.7 n 维 Brown 运动与牛顿位势

1° 对 $\forall 0 \leq t_1 < t_2 < \cdots < t_m$, $X(t_1) - X(0), X(t_2) - X(t_1), \cdots, X(t_m) - X(t_{m-1})$ 相互独立.

2° 对 $\forall s \geq 0, t > 0$, 增量 $X(t+s) - X(s)$ 为 n 维正态分布, 其 p.d.f. 为

$$P(t, x) = \frac{1}{(2\pi t)^{\frac{n}{2}}} \exp\left(-\frac{|x|^2}{2t}\right), \quad x \in \mathbb{R}^n \quad (5.7.1)$$

其中 $|x| = (\sum_{i=1}^n x_i^2)^{\frac{1}{2}}$.

3° 对每一 $\omega \in \Omega$, $X(t, \omega)$ 是 t 的连续函数.

则称 $\{X(t), t \geq 0\}$ 为 n 维 Brown 运动. □

简记 $X(t)$ 为 X_t , 设初始分布 $\mu(A) = P(X(0) \in A)$, 其中 $A \in \mathbb{R}^n$. (5.7.1) 式给出了 $X(s+t) - X(s)$ 的 p.d.f, 由此可求 $X(t)$ 的 p.d.f. 因 $X(t) = X(t) - X(0) + X(0)$, 由 (5.7.1) 式及卷积公式, 得

$$P(X(t) \in A) = \int_A \left\{ \int_{\mathbb{R}^n} \frac{1}{(2\pi t)^{n/2}} \exp\left(-\frac{|x-y|^2}{2t}\right) \mu dx \right\} dy. \quad (5.7.2)$$

为了突出 μ 的作用, 有时记:

$$P_\mu(X(t) \in A) = P(X(t) \in A). \quad (5.7.3)$$

n 维 BM $\{X(t), t \geq 0\}$ 有以下简单性质:

1° 设 H 是 \mathbb{R}^n 中的正交变换, 则 $HX = \{HX(t), t \geq 0\}$ 也是 n 维 BM.

2° 设 $a \in \mathbb{R}^n$ 固定, $\{X(t) + a, t \geq 0\}$ 也是 BM.

3° 设 $c > 0$ 为常数 ($c \in \mathbb{R}^1$), 则 $\{\frac{X(ct)}{\sqrt{c}}, t \geq 0\}$ 也是 BM.

证明 只证 1°, 其余两个可类似地证明.

由于 $H(X(s+t)) - H(X(s)) = H(X(s+t) - X(s))$ 只依赖于 $X(s+t) - X(s)$, 故由 X 的增量独立, 即得 HX 的增量独立性.

其次, X 对 t 连续, 故 HX 也连续. 由 (5.7.1) 式知 $X(s+t) - X(s)$ 的特征函数为

$$E\{\exp[i(X(s+t) - X(s), y)]\} = \exp\{-(y, y)t/2\}, \quad y \in \mathbb{R}^n \quad (5.7.4)$$

其中 $(x, y) = \sum_{i=1}^n x_i y_i$.

由正交变换保持内积不变, 并利用 (5.7.4) 式及 H^{-1} 也是正交变换, 得

$$\begin{aligned} E\{\exp[i(H(X(s+t) - X(s)), y)]\} &= E\{\exp[i(X(s+t) - X(s), H^{-1}(y))]\} \\ &= \exp\{-(H^{-1}(y), H^{-1}(y)) \cdot \frac{t}{2}\} = \exp[-(y, y)t/2] \end{aligned} \quad (5.7.5)$$

所以 $HX(s+t) - HX(s)$ 的 p.d.f. 与 (1) 相同, 故 HX 也是 n 维 BM. □

类似于 1 维 Brown 运动, n 维 Brown 运动也具有马氏性, 正态性, 鞅的性质. 这里不在述. 读者可对照 1 维情形自己推导.

转移概率密度 $P(t, x, y)$ 的性质.

记

$$P(t, x, y) \triangleq P(t, y - x) = \frac{1}{(2\pi t)^{\frac{n}{2}}} \exp\left(-\frac{|y - x|^2}{2t}\right). \quad (5.7.6)$$

其中 $t \geq 0, x, y \in \mathbb{R}^n$.

由 (5.7.2) 式知, 若 $X(0) = x \in \mathbb{R}^n$ 固定, 或 μ 集中在单点集 x 上, 并记 P_μ 为 P_x , 则

$$P_x(X(t) \in A) = \int_A P(t, x, y) dy \quad (5.7.7)$$

$P(t, x, y)$ 可以直观解释为: 作 BM 的粒子由 x 点出发, 于时刻 t 转移到点 y 附近的转移密度即为 $P(t, x, y)$. 易知, $P(t, x, y)$ 关于 x, y 是对称的.

下列定理说明 BM 与牛顿位势之间的重要联系.

定理 5.7.1

$$g(x, y) = \int_0^\infty P(t, x, y) dt = \begin{cases} \frac{\Gamma(\frac{n}{2}-1)}{2\pi^{n/2}} \cdot \frac{1}{|x-y|^{n-2}}, & n \geq 3, \\ \infty, & n \leq 2. \end{cases} \quad (5.7.8)$$

其中 $\Gamma(\alpha) = \int_0^\infty x^{\alpha-1} e^{-x} dx$.

记 $C_n = \frac{\Gamma(\frac{n}{2}-1)}{2\pi^{\frac{n}{2}}}$,

则

$$C_n = \begin{cases} \frac{1}{2\pi}, & n = 3 \\ \frac{1}{2\pi^2}, & n = 4 \\ \frac{1 \cdot 3 \cdots (2k-3)}{(2\pi)^k}, & n = 2k + 1 > 3 \\ \frac{1 \cdot 2 \cdots (k-2)}{2\pi^k}, & n = 2k > 4. \end{cases} \quad (5.7.9)$$

证明 $\forall s > 0$, 有

$$\begin{aligned} \int_0^s P(t, x) dt &= \frac{1}{(2\pi)^{n/2}} \int_0^s \frac{1}{t^{n/2}} \exp\left(-\frac{|x|^2}{2t}\right) dt \quad (\text{令 } u = \frac{|x|^2}{2t}) \\ &= \frac{1}{(2\pi)^{n/2}} \int_{+\infty}^{\frac{|x|^2}{2s}} \frac{(2u)^{\frac{n}{2}}}{|x|^n} e^{-u} \cdot \frac{|x|^2}{2} \cdot \left(-\frac{1}{u^2}\right) du \\ &= |x|^{2-n} \cdot 2^{-1} \pi^{-n/2} \int_{|x|^2/2s}^\infty u^{\frac{n}{2}-2} \exp(-u) du \\ &= 2^{-1} |x|^{2-n} \cdot \pi^{-n/2} \int_{\frac{|x|^2}{2s}}^\infty u^{(\frac{n}{2}-1)-1} \exp(-u) du. \end{aligned}$$

当且仅当 $\frac{n}{2} - 1 > 0$, 即 $n \geq 3$ 时

$$\lim_{s \rightarrow \infty} \frac{1}{2\pi^{n/2}} \int_{\frac{|x|^2}{2s}}^\infty u^{(\frac{n}{2}-1)-1} e^{-u} du = \frac{\Gamma(\frac{n}{2}-1)}{2\pi^{n/2}}.$$

$$\text{故 } \int_0^\infty P(t, x, y) dt = \begin{cases} \frac{\Gamma(\frac{n}{2}-1)}{2\pi^{n/2}} \cdot \frac{1}{|x-y|^{n-2}}, & n \geq 3, \\ \infty, & n \leq 2. \end{cases}$$

□

5.7 n 维 Brown 运动与牛顿位势

$g(x, y)$ 的直观意义是：从 x 点出发经有限时间转到 y 附近的概率密度.

下面简要介绍关于电荷产生的位势，再有它与 $g(x, y)$ 之间的关系.

1° 点电荷产生的位势

设在点 y_0 处有一电荷 q_0 ，它在任一点 $x (x \neq y_0)$ 产生的电位势等于把一单位电荷从无穷远处移到 x 点所作的功，其电位势的值为： $\frac{1}{2\pi} \cdot \frac{q_0}{|x - y_0|}$.

2° m 个点电荷 q_i 分别在点 $y_i (i = 1, 2, \dots, m)$ ，即

$$y_1, y_2, \dots, y_i, \dots, y_m,$$

$$q_1, q_2, \dots, q_i, \dots, q_m.$$

可看作离散点电荷的分布 (与离散 r.v. 的分布律相似)，这 m 个点电荷在 x 点产生的位势为：

$$\frac{1}{2\pi} \sum_{i=1}^m \frac{q_i}{|x - y_i|}.$$

3° 现设电荷按一测度 $\mu(y)$ 分布，它表示在 $(y, y + dy)$ 上约有电荷 $d\mu(y)$. 定义由 $\mu(y)$ 在 x 点产生的电位势为 $G\mu(x) = \frac{1}{2\pi} \int_{\mathbb{R}^n} \frac{d\mu(y)}{|x - y|}$. 从分析的观点看，上式定义了一个积分变换 G ，它把测度 μ 变为函数 $G\mu$. 由定理 5.7.1 可知，上述积分变换的核 $\frac{1}{2\pi} \frac{1}{|x - y|}$ 恰好就是 3 维 BM 转移概率密度对时间 t 的积分 $g(x, y)$. 这正是 BM 与牛顿位势联系起来的纽带之一.

若考虑 \mathbb{R}^n 中，记 $x = (x_1, x_2, \dots, x_n)$, $|x| = (\sum_{i=1}^n x_i^2)^{\frac{1}{2}}$, 对 $r > 0$, 记 $B(r) = \{x : |x| \leq r\}$, $B^o(r) = \{x : |x| < r\}$, $S(r) = \{x : |x| = r\}$. 它们分别表示 \mathbb{R}^n 中以原点为中心， r 为半径的球、开球和球面. 设 $y \geq 0$, $f(y)$ 是 y 的函数，若以下左边积分存在，则有

$$\int_{B(r)} f(|x|) dx = \frac{2\pi^{\frac{n}{2}}}{\Gamma(\frac{n}{2})} \int_0^r s^{n-1} f(s) ds.$$

若取 $f \equiv 1$ ，并利用 $\Gamma(x+1) = x\Gamma(x)$ ，可得球 $B(r)$ 的体积：

$$|B(r)| = \frac{\pi^{\frac{n}{2}} \cdot r^n}{\Gamma(n/2 + 1)}.$$

上式对 r 微分，可得球面 $S(r)$ 的面积：

$$|S(r)| = \frac{2\pi^{n/2} \cdot r^{n-1}}{\Gamma(\frac{n}{2})} \quad (5.7.10)$$

$r = 1$ 时，有

$$|S(1)| = \frac{2\pi^{n/2}}{\Gamma(\frac{n}{2})}. \quad (5.7.11)$$

与 (5.7.8)、(5.7.9) 式比较得

$$C_n = \frac{2}{(n-2)|S(1)|}$$

$$\int_0^\infty P(t, x, y) dt = \frac{2}{(n-2)|S(1)|} \cdot \frac{1}{|y-x|^{n-2}}, \quad (n \geq 3).$$

接下来要讨论的是所谓半群及无穷小生成算子.

设 $f(x)$ 为定义在 \mathbb{R}^n 上的函数, 记

$$B = \{f : f \text{ 有界} \}$$

$$C = \{f : f \in B \text{ 且 } f \text{ 连续} \}$$

$$C_0 = \{f : f \in C \text{ 且 } f(\infty) = \lim_{x \rightarrow \infty} f(x) = 0\}.$$

$\|f(t)\| = \sup_x |f(x)|$, 对 $f \in C$, 定义变换 T_t 如下:

$$T_t f(x) = \int_{\mathbb{R}^n} f(y) P(t, x, y) dy, \quad (t > 0). \quad (5.7.12)$$

显然有

1°

$$\|T_t f\| \leq \|f\|, \quad \|T_t\| \leq 1. \quad (5.7.13)$$

同时还有以下一些性质:

$$2^\circ \quad T_t C_0 \subset C_0$$

证明 对 $\forall f \in B$, 则有

$$|T_t f(x) - T_t f(x_0)| \leq \|f\| \cdot \frac{1}{(2\pi t)^{n/2}} \int_{\mathbb{R}^n} |e^{-|x-y|^2/2t} - e^{-|x_0-y|^2/2t}| dy.$$

当 $x \rightarrow x_0$ 时, 上式 $\rightarrow 0$, 即 $T_t f(x)$ 连续, 即 $T_t f(x) \in C$, $T_t B \subset C_0$.

对 $\forall f \in C_0$, $N > 0$, 有

$$|T_t f(x)| \leq \int_{|y|>N} \frac{1}{(2\pi t)^{n/2}} \exp\left(-\frac{|x-y|^2}{2t}\right) |f(y)| dy + \|f(x)\| \int_{|y|<N} \frac{1}{(2\pi t)^{n/2}} \exp\left(-\frac{|x-y|^2}{2t}\right) dy.$$

由 $f(\infty) = 0$ 知, 对 $\forall \varepsilon > 0$, 当 N 充分大后, 第一个积分式小于 $\frac{\varepsilon}{2}$. 固定此 N , 当 $|x|$ 充分大时, 第二个积分小于 $\frac{\varepsilon}{2}$, 于是 $T_t f(\infty) = 0$, 即 $T_t C_0 \subset C_0$. \square

此外还有下述定理.

定理 5.7.2 设 f 一致连续, 则

$$\lim_{t \rightarrow 0} \|T_t f - f\| = 0. \quad (5.7.14)$$

证明 对 $\forall \varepsilon > 0$, 由于 f 一致连续, 存在 $\delta > 0$, 使对 $\forall y$, 有 $\sup_{|x|<\delta} |f(x+y) - f(y)| < \frac{\varepsilon}{2}$, 所以

$$\begin{aligned} \|T_t f - f\| &\leq \sup \left[\int_{|x|<\frac{\varepsilon}{2}} + \int_{|x|\geq\frac{\varepsilon}{2}} \right] \cdot \frac{1}{(2\pi t)^{n/2}} \exp\left(-\frac{|x|^2}{2t}\right) |f(x+y) - f(y)| dx \\ &\leq \frac{\varepsilon}{2} + 2\|f\| \int_{|x|\geq\frac{\varepsilon}{2}} \frac{1}{(2\pi t)^{n/2}} e^{-\frac{|x|^2}{2t}} dx \\ &= \frac{\varepsilon}{2} + 2\|f\| \int_{|u|\geq\frac{\varepsilon}{2\sqrt{t}}} \frac{1}{(2\pi)^{n/2}} e^{-\frac{|u|^2}{2}} du. \end{aligned}$$

5.7 n 维 Brown 运动与牛顿位势

当 t 充分小时, 第二项积分小于 $\frac{\varepsilon}{2}$, 所以

$$\lim_{t \rightarrow 0} \|T_t f - f\| = 0. \quad \square$$

由定理 5.7.2, 我们定义

$$T_0 f = f, \quad T_0 = I (\text{恒等算子})$$

对 $t \rightarrow \infty$, 我们有

定理 5.7.3 若 $f \in C_0$, 则

$$\lim_{t \rightarrow \infty} \|T_t f\| = 0,$$

(证明从略).

下面证 T_t 具有重要的半群性, 即

定理 5.7.4 $\forall s, t \geq 0, T_0 = I$, 有

$$T_{s+t} = T_s \cdot T_t \quad (5.7.15)$$

证明

$$\begin{aligned} T_s T_t f(z) &= (2\pi s)^{-\frac{n}{2}} (2\pi t)^{-\frac{n}{2}} \int_{\mathbb{R}^n} \int_{\mathbb{R}^n} \exp\left(-\frac{|y-z|^2}{2s} - \frac{|x-y|^2}{2t}\right) f(x) dx dy \\ &= (2\pi)^{-n} (st)^{-\frac{n}{2}} \int_{\mathbb{R}^n} \int_{\mathbb{R}^n} e^{-\frac{|x-z|^2}{2(s+t)}} \\ &\quad \cdot \exp\left\{-\frac{|y-(zt+xs)(s+t)^{-1}|^2}{2st(s+t)^{-1}}\right\} f(x) dy dx. \end{aligned}$$

由于 $[2\pi \cdot \frac{st}{s+t}]^{-\frac{n}{2}} \int_{\mathbb{R}^n} \exp\left\{-\frac{|y-(zt+xs)(s+t)^{-1}|^2}{2st(s+t)^{-1}}\right\} dy = 1$.

故 $T_s T_t f(z) = [2\pi(s+t)]^{-\frac{n}{2}} \int_{\mathbb{R}^n} \exp\{-|x-z|^2/2(s+t)\} f(x) dx = T_{s+t} f(z)$.

即: $T_s T_t = T_s \cdot T_t \quad \square$

由上可知, $\{T_t, t \geq 0\}$ 构成作用于 C 上的线性算子压缩半群.

引理 1 若 f 一致连续, 或 $f \in C_0$, 则 $T_t f(x)$ 对 $t \geq 0$ 一致连续, 且此连续性对 $x \in \mathbb{R}^n$ 也是一致的.

证明 利用 T_t 的半群性, 压缩性及定理 5.7.2, 对 $\forall h > 0$, 有

$$\|T_{t+h} f - T_t f\| \leq \|T_t\| \cdot \|T_h f - f\| \leq \|T_h f - f\|.$$

当 $h \rightarrow 0$ 时, 上式 $\rightarrow 0$.

对 $h = -\varepsilon < 0$, 有

$$\|T_{t+h} f - T_t f\| \leq \|T_{t-\varepsilon}\| \cdot \|f - T_\varepsilon f\| \leq \|T_\varepsilon f - f\|.$$

175

$h \rightarrow 0$ 时, 上式也趋于 0. \square

注: 按范数 $\|\cdot\|$ 的收敛称为强收敛, 记为 $S-\lim$.

定义 2 对 $f \in C$, 记

$$Af \triangleq S - \lim_{h \rightarrow 0^+} \frac{T_h f - f}{h} \triangleq g \quad \text{或} \quad Af = g. \quad (5.7.16)$$

$$D_A = \{f : f \in C \text{ 且 } Af = g \in C\} \quad (5.7.17)$$

称 A 为半群 $\{T_t, t \geq 0\}$ 或过程 $\{X(t), t \geq 0\}$ 的强无穷小算子. D_A 为 A 的定义域. \square

以下定理则把 BM 与 Laplace 算子联系起来:

定理 5.7.5 设 f 有界, 二次连续可微, 二阶偏导有界且在 \mathbb{R}^n 上一致连续, 则 $\forall f \in D_A$, 有

$$Af(x) = \frac{1}{2} \sum_{i=1}^n \frac{\partial^2 f(x)}{\partial x_i^2} \triangleq \frac{1}{2} \Delta f(x)$$

其中 $x = (x_1, x_2, \dots, x_n)$, $\Delta = \sum_{i=1}^n \frac{\partial^2}{\partial x_i^2}$ 是熟知的 Laplace 算子.

证明 令 $y = x + \sqrt{t}z$, 即 $y_I = x + \sqrt{t}z_i$, $i = 1, 2, \dots, n$,

$$\begin{aligned} T_t f(x) &= (2\pi t)^{-\frac{n}{2}} \int_{\mathbb{R}^n} \exp\left(-\frac{|y-x|^2}{2t}\right) f(y) dy \\ &= (2\pi t)^{-\frac{n}{2}} \int_{\mathbb{R}^n} \exp\left(-\frac{|z|^2}{2}\right) f(x + \sqrt{t}z) dz. \end{aligned} \quad (5.7.18)$$

记 $f_i = \frac{\partial f}{\partial x_i}$, $f_{ij} = \frac{\partial^2 f}{\partial x_i \partial x_j}$, 并利用 Taylor 展开式:

$$\begin{aligned} f(x + \sqrt{t}z) &= f(x) + \sqrt{t} \sum_{i=1}^n z_i f_i(x) + \frac{t}{2} \sum_{i=1}^n \sum_{j=1}^n z_i z_j f_{ij}(x) \\ &\quad + \frac{t}{2} \sum_{i=1}^n \sum_{j=1}^n [f_{ij}(\bar{x}) - f_{ij}(x)] z_i z_j. \end{aligned} \quad (5.7.19)$$

其中 \bar{x} 的坐标在 x 与 $x + \sqrt{t}z$ 的坐标之间, 以 (5.7.19) 代入 (5.7.18), 并注意到

$$\begin{aligned} \int_{\mathbb{R}^n} \exp\{-z^2/2\} z_i f_i(x) dz &= 0, \quad i = 1, 2, \dots, n \\ \int_{\mathbb{R}^n} \exp\{-z^2/2\} z_i z_j f_{ij}(x) dz &= 0, \quad i \neq j. \\ \int_{\mathbb{R}^n} \exp\{-z^2/2\} z_i^2 f_{ii}(x) dz &= f_{ii}(x), \quad i = 1, 2, \dots, n \end{aligned}$$

得

$$T_t f(x) = f(x) + \frac{t}{2} \Delta f(x) + (2\pi)^{-\frac{n}{2}} \cdot \frac{t}{2} J(t, x) \quad (5.7.20)$$

其中 $J(t, x) = \int_{\mathbb{R}^n} \exp\{-z^2/2\} \sum_{i=1}^n \sum_{j=1}^n [f_{ij}(\bar{x}) - f_{ij}(x)] z_i z_j dz$

令 $F(x, z, t) = \max_{ij} |f_{ij}(\bar{x}) - f_{ij}(x)|$, 则对 $\forall s > 0$, 有

$$\begin{aligned} |J(t, x)| &\leq \int_{\mathbb{R}^n} e^{-\frac{z^2}{2}} \sum_{i=1}^n \sum_{j=1}^n F(x, z, t) \frac{z_i^2 + z_j^2}{2} dz \\ &= n \int_{\mathbb{R}^n} F(x, z, t) \exp\{-z^2/2\} z^2 dz \quad (z^2 = \sum_{i=1}^n z_i^2) \\ &\leq n \int_{|z| < s} F(x, z, t) z^2 \exp\{-z^2/2\} dz + 2n \max_{ij} \|f_{ij}\| \cdot n \cdot \int_{|z| \geq s} z^2 \exp\{-z^2/2\} dz \\ &= I + II. \end{aligned}$$

5.7 n 维 Brown 运动与牛顿位势

由 f_{ij} 一致连续性, 当 $t \rightarrow 0$ 时, I 对 x 均匀地趋于 0, 故对任意的 $s > 0$, 有

$$\limsup_{t \rightarrow 0} \sup_x |J(t, x)| \leq 2 \max_{i,j} \|f_{ij}\| \cdot n \int_{|z| \geq s} z^2 \cdot \exp\{-z^2/2\} dz$$

$s \rightarrow \infty$ 时, 上式右方趋于 0. 故

$$\lim_{t \rightarrow 0} \sup_x |J(t, x)| = 0$$

从而, 由 (5.7.20) 式得

$$\lim_{t \rightarrow 0} \left\| \frac{T_t f - f}{t} - \frac{1}{2} \Delta f \right\| = 0.$$

定理得证. \square

与一维 BM 一样, 在 n 维 BM 中首中时也是一个很有用的概念.

设 $\{X(t), t \geq 0\}$ 是 n 维 BM, $A \subset \mathbb{R}^n$,

$$T_A(\omega) = \inf\{t : t > 0, X(t) \in A\},$$

称 T_A 为 A 的首中时 (Hitting Time), 亦称为 $A^C = \mathbb{R}^n - A$ 的首出时.

$X(T_A)$ 为集合 A 的首中点. 显然如 A 为紧集, 则 $X(T_A) \in A$, 一般 $X(T_A) \in \bar{A}$.

若对 $x \in \mathbb{R}^n$, 有 $P\{T_A = 0 | X(0) = x\} = 1$, 则称 x 为 A 的规则点, 否则称为 A 的不规则点. 直观地说, 作 Brown 运动的粒子从 x 点出发能立即击中 A 的点是 A 的规则点.

定义 3 设 $A \subset \mathbb{R}^n$ 为任一开集, 若函数 $h(x) (x \in \mathbb{R}^n)$ 在 A 中连续, $\frac{\partial^2 h}{\partial x_i^2} (i = 1, 2, \dots, n)$ 存在, 且满足 Laplace equation:

$$\Delta h = \sum_{i=1}^n \frac{\partial^2 h}{\partial x_i^2} = 0. \quad (5.7.21)$$

则称 $h(x)$ 为调和函数. \square

例 1 设 a 为任一点, C_1, C_2 为常数, 则

$h(x) = C_1 + C_2/|x - a|^{n-2}$, ($n \neq 2$) 在 $\mathbb{R}^n - \{a\}$ 中调和

$h(x) = C_1 + C_2 \ln |x - a|$, ($n = 2$) 在 $\mathbb{R}^n - \{a\}$ 中调和

本节最后部分要介绍 Dirichlet 问题的概率表示.

设 $A \subset \mathbb{R}^n$ 开集, $n \geq 2$, A 的边界记为 ∂A , $A^\circ = A - \partial A$, 设 $f(x)$ 为在 ∂A 上的已知连续函数, 求 $h(x)$ 使满足

$$\begin{cases} \Delta h \equiv 0, & x \in A^\circ, \\ h(x) = f(x), & x \in \partial A. \end{cases} \quad (5.7.22)$$

称上述问题为 D-问题, 是 Gauss 于 1840 年提出的. 1924 年, Wiener 提出了广义 D-问题, 1944 年 Kakutani, 1954 年 Doob 又分别发现了 D-问题的解与 BM 的内在联系.

D-问题是否有解, 依赖于对 A 的边界 ∂A 上的点是否对 A^C 规则.

定理 5.7.6 设 A 为有界开集, $A \subset \mathbb{R}^n$, ($n \geq 2$), 则 D-问题 (5.7.22) 有解的充要条件是 ∂A 的每一点都是 $A^C = \mathbb{R}^n - A$ 的规则点; 此时解 $h(x)$ 唯一, 且可表示为:

$$h(x) = E_x[f(X(T_{A^C}))], \quad x \in A. \quad (5.7.23)$$

其中 T_{A^C} 为 A^C 的首中时, E_x 表示在 $X(0) = x$ 下的条件期望.

证明 : (从略).

(5.7.23) 式是很有意义的, 它将求解 Laplace 方程与 n 维 BM 联系起来.

§ 5.8 用 Monte-Carlo 方法求解 Laplace 方程


上节介绍了 D-问题的概率表示, 本节介绍用 Monte-Carlo 方法给出这些方程的数值解. 为简单起见, 仅以 $n = 2$ 为例说明.

求 $h(a) = h(x, y)$ 满足

$$\begin{cases} \frac{\partial^2 h}{\partial x^2} + \frac{\partial^2 h}{\partial y^2} = 0, & a = (x, y) \in A, \\ h(x, y) = f(x, y), & a = (x, y) \in \partial A. \end{cases} \quad (5.8.1)$$

其中 $f(x, y) = f(a)$ 为已知函数, $a = (x, y)$.

我们用网格法将 (5.8.1) 离散化, 化为差分方程, 在 A 上作步长为 h 的网格, 交点称为结点. 把“最”接近边界 ∂A 的点构成 ∂A_h , 作为对应差分方程的边界点, A 中其余的结点记为 A_h , 如 5.8.1 图. (在本章练习后)



由微分方程的理论知, (5.8.1) 对应的差分方程为

$$\begin{cases} h(a) = \frac{1}{4}[h(a_1) + h(a_2) + h(a_3) + h(a_4)], & a \in A_h, \\ h(a) = f(a), & a \in \partial A_h. \end{cases} \quad (5.8.2)$$

其中 a_1, a_2, a_3, a_4 为 a 的四个相邻的结点.

为解 (5.8.2), 设计平面上的随机游动如下: 一质点 M 自 $a \in A$ 出发作随机游动, 它下一步到达四邻点之一的概率各为 $\frac{1}{4}$, 再下一步又同样以 $\frac{1}{4}$ 的概率到达该点的四邻点之一, 且各次游动相互独立. 如此继续, 直至首次到达 ∂A_h , 质点被吸收停止运动. 用 $\xi = (x, y)$ 表示质点 M 首次到达 ∂A_h 的点. 它是一个 r.v., 以 $v(a)$ 表示质点 M 从 a 点出发条件下, $f(\xi)$ 的数学期望, 即 $v(a) = E\{f(\xi)|\text{从 } a \text{ 出发}\}$, 易证 $v(a) < \infty$ 存在 (这里从略). 同时 $v(a)$ 是 (5.8.2) 的解. 证明如下

以 $P(a, b)$ 表示从 a 出发的质点被吸收于 $b \in \partial A_h$ 的概率, 若 $a \in A_h$, 则

$$P(a, b) = \frac{1}{4} \sum_{i=1}^4 P(a_i, b).$$

$$v(a) = \sum_{b \in \partial A_h} P(a, b) f(b) = \frac{1}{4} \sum_{i=1}^4 \sum_{b \in \partial A_h} P(a_i, b) f(b) = \frac{1}{4} \sum_{i=1}^4 v(a_i).$$

所以 $v(a)$ 满足 (5.8.2) 的前一式. 若 $a \in \partial A_h$, 则

$$P(a, b) = \begin{cases} 1, & \text{若 } a = b \\ 0, & \text{若 } a \neq b \end{cases}$$

$$v(a) = \sum_{b \in \partial A_h} P(a, b) f(b) = f(a).$$

即 $v(a)$ 对 (5.8.2) 的后一式也满足.

注意: (5.8.2) 的解 $v(a)$ 依赖于 h , 当 h 充分小时, (5.8.2) 的解 $v(a)$ 近似于 (5.8.1) 的解.

以上就是用随机模拟方法求解 Laplace equation 的基本思想.

那么, 如何求出 $v(a)$ 的近似值呢?

令质点 M 从 a 出发按上述规则作随机游动直到质点第一次到达边界 ∂A_h . 记下到达点的位置 ξ . 重复上述实验 m 次 (m 足够大), 设第 k 次的到达点为 $\xi_k (1 \leq k \leq m)$, 取

$$\bar{v}_m(a) = \frac{1}{m} \sum_{k=1}^m f(\xi_k).$$

由大数定理有

$$P(\lim_{m \rightarrow \infty} \bar{v}_m(a) = v(a)) = 1.$$

及

$$E\{\bar{v}_m(a)\} = v(a).$$

即 $\bar{v}_m(a)$ 是 $v(a)$ 的一致估计与无偏估计.

如果给出误差精度 $\delta > 0$ 及置信度 $\alpha (0 < \alpha < 1)$, 就可以根据中心极限定理, 确定所需实验次数 m , 使满足

$$P(|\bar{v}_m(a) - v(a)| \leq \delta) = \alpha, \quad a \in A_h.$$

练习题

设 $\{B(t), t \geq 0\}$ 为标准 BM, $B(0) = 0$. $X(t) = B(t) + \mu t$, $Z(t) = B(t) - tB(1)$, $P(x, t) = (2\pi t)^{-1/2} \exp(-\frac{x^2}{2t})$, $T_a = \inf\{t : t > 0, B(t) = a\}$ 。

5.1

1° 求 $cov(B(s), B(t))$;

2° 给定 $B(s) = x$, 求 $B(s+t)$ 的条件概率密度;

3° 证 $\frac{\partial p}{\partial t} = \frac{1}{2} \frac{\partial^2 p}{\partial x^2}$;

4° $\forall 0 \leq s < t < u$, 给定 $B(s) = x$, $B(u) = y$, 求 $B(t)$ 的条件概率密度, 并利用这个结果求 $E[B(t)|B(s) = x, B(u) = y] = ?$ 及 $Var[X(t)|B(s) = x, B(u) = y] = ?$;

5° $\forall 0 \leq t_1 < t_2 < \cdots < t_n < t_{n+1}$, 给定 $B(t_i) = x_i$, $1 \leq i \leq n$, 求 $B(t_{n+1})$ 的条件概率密度, 及 $\forall x \in R^1$, 求

$$P\{B(t_{n+1}) \leq x | B(t_1) = x_1, \cdots, B(t_n) = x_n\},$$

$$E\{B(t_{n+1}) | B(t_1), B(t_2), \cdots, B(t_n)\},$$

$$Var\{B(t_{n+1}) | B(t_1) = x_1, \cdots, B(t_n) = x_n\}.$$

6° $\forall 0 \leq t_{n+1} < t_n < t_{n-1} < \cdots < t_1$, 给定 $B(t_i) = x_i$, $1 \leq i \leq n$ 。求 $B(t_{n+1})$ 的条件概率密度函数, 从而证明 $\{B(t), t \geq 0\}$ 从逆向时间看亦是马氏过程。

7° 求 $E(B(2)|B(3))$, $E(B(2)B(4)|B(3))$, $E(B(2)B(6)|B(3), B(4), B(5))$ 。

5.2 令 $Y(t) = tB(\frac{1}{t})$, $Y(0) \triangleq 0$, $W(t) = \frac{1}{a}B(a^2t)$, $a > 0$, $U(t) = (t+1)Z(t/(t+1))$, 证明 $\{Y(t), t \geq 0\}$, $\{W(t), t \geq 0\}$, $\{U(t), t \geq 0\}$ 都是 BM。

5.3 令 $V(t) = \exp(-\alpha t)B[\exp(2\alpha t)]$, 求证 $\{V(t), t \geq 0\}$ 是平稳正态过程 (称为 Ornstein-Uhlenback 过程) 并求 $E(V(s)V(t))$ 及 $V(t)$ 的概率密度函数。

5.4 求 $|B(t)|$, $|\min_{0 \leq s \leq t} B(s)|$, $M(t) = \max_{0 \leq s \leq t} (B(s))$ 及 $\delta(t) = M(t) - B(t)$ 的分布。

180

5.5 求 $S(t) = \int_0^t B(s)ds$ 的协方差、方差及 $(S(t_1), S(t_2))$ 的联合概率密度函数。

5.6 求 $E(e^{S(t)})$ 及 $cov(e^{S(t_1)}, e^{S(t_2)})$ 。

练习题

5.7 $Q(t) = B^2(t) - t$, $\forall s, t \geq 0$, 证 $E\{Q(s+t)|B(s)\} = Q(s)$ 。

5.8 证明 $\{|B(t)|t \geq 0\}$ 与 $\{\delta(t), t \geq 0\}$ 二过程是等价的, 且它们是马氏过程。

5.9 令 $\eta(t) = e^{B(t)}$, 试求 $\alpha(x) = \lim_{h \rightarrow 0} \frac{E[\eta(t+h) - \eta(t)|\eta(t)=x]}{h}$

和 $\beta(x) = \lim_{h \rightarrow 0} \frac{E\{[\eta(t+h) - \eta(t)]^2 | \eta(t)=x\}}{h}$ 。

5.10 证明 $P\{M(t) > x | B(t) = M(t)\} = \exp(-\frac{x^2}{2t})$ 。提示: 求在给定 $\delta(t) = M(t) - B(t) = 0$ 下 $M(t)$ 的条件分布。

5.11 设 $\mu < 0$, $M = \max_{t \geq 0} X(t)$, 证 $\alpha \geq 0$, $P(M > \alpha) = \exp(2\mu\alpha)$ 。

5.12 设 $\alpha, \beta > 0$, 证 $P\{B(t) \leq \alpha t + \beta \text{ 对所有 } t \geq 0 | B(0) = x\} = 1 - \exp[-2\alpha(\beta - x)] (x \leq \beta)$ 。

5.13 设 $\alpha, \beta > 0$, 证 $P\{B(u) < \alpha u + \beta, 0 \leq u \leq 1 | B(0) = B(1) = 0\} = 1 - \exp[-2\beta(\beta + \alpha)]$ 。

5.14 设 $n \geq 1$, $1 \leq k \leq 2^n$, 记 $\Delta_{nk} = B(\frac{k}{2^n}) - B(\frac{k-1}{2^n})$, $S_n = \sum_{k=1}^{2^n} \Delta_{nk}^2$,

1° 求 ES_2 , $E(\Delta_{nk} | \Delta_{nk}^2)$, $E(\Delta_{nk} \Delta_{nk+1} | \Delta_{nk}^2, \Delta_{nk+1}^2)$, $E(S_3 | S_2)$ 及 $E(S_2 | S_3)$;

2° 证 $E(S_{n+1} | S_n) = \frac{1}{2}(S_n + 1)$ 及 $E(S_n | S_{n+1}) = S_{n+1}$ 。

5.15 对 $\forall x > 0$, 及充分小的 $h > 0$, 证 $P\{\max_{0 \leq s \leq h} |X(s)| > x | B(0) = 0\} = o(h)$ 。

5.16 求 $P(T_1 < T_{-1} < T_2)$ 。提示: 利用全概公式及 BM 的对称性。

5.17 令 $T = \inf\{t : t > 0, X(t) = a \text{ 或 } X(t) = -b\}$, $a, b > 0$, $-b < x < a$, 记 $g(x) = E(T | X(0) = x)$, 试导出 $g(x)$ 满足的微分方程, 并求出 $g(x)$ 的表达式。

5.18 记 $P(t; x, y) \triangleq P(x - y, t) = \frac{1}{\sqrt{2\pi t}} \exp(-\frac{(x-y)^2}{2t})$

1° 设 $f(x)$ 在 $(-\infty, +\infty) = R^1$ 上一致连续, 证

$$\lim_{t \rightarrow 0} \int_{-\infty}^{+\infty} P(t; x, y) f(y) dy = f(x).$$

2° 若 $f(x)$ 在 R^1 一致连续, 且具有二阶一致连续导数, 证

$$\lim_{t \rightarrow 0} \frac{1}{t} \int_{-\infty}^{+\infty} P(t; x, y) (f(y) - f(x)) dy = \frac{1}{2} f''(x).$$

5.19 设 $x, y \in R^n$, $|x|^2 = \sum_{i=1}^n x_i^2$, 记

$$P(t; x, y) = (2\pi t)^{-\frac{n}{2}} \exp(-\frac{|x-y|^2}{2t}), \quad f(x) : R^n \rightarrow R^1.$$

1° 若 $f(x)$ 在 R^n 上一致连续, 定义

$$T_t f(x) = \int_{R^n} P(t; x, y) f(y) dy$$

证 $\lim_{t \rightarrow 0} T_t f(x) = f(x)$, $T_t T_s f(x) = T_{s+t} f(x)$ 。

2° 若 $f(x)$ 在 R^n 上有界, 一致连续且具二阶偏导数一致连续, 证

$$\lim_{t \rightarrow 0} \frac{T_t f(x) - f(x)}{t} = \frac{1}{2} \sum_{i=1}^n \frac{\partial^2 f}{\partial x_i^2} \triangleq \frac{1}{2} \Delta f(x).$$

3° 证

$$g(x, y) = \int_0^\infty P(t : x, y) dt = \begin{cases} \frac{\Gamma(\frac{n}{2}-1)}{2\pi^{\frac{n}{2}}} \cdot \frac{1}{|y-x|^{n-2}} & (n \geq 3) \\ \infty & (1 \leq n \leq 2). \end{cases}$$

第六章 连续参数马氏链

在第三章里, 我们曾详细地讨论了离散参数马氏链的有关问题, 本章将着重研究连续参数可列状态空间的马氏过程.

仍记状态空间为 $S = \{0, 1, 2, \dots\}$

定义 设随机过程 $X = \{X(t), t \geq 0\}$ 对于任意 $0 \leq t_0 < t_1 < \dots < t_n < t_{n+1}$, $i_k \in S$, $0 \leq k \leq n+1$, 若对 $P\{X(t_0) = i_0, X(t_1) = i_1, \dots, X(t_n) = i_n\} > 0$ 就有

$$\begin{aligned} P\{X(t_{n+1}) = i_{n+1} | X(t_0) = i_0, X(t_1) = i_1, \dots, X(t_n) = i_n\} \\ = P\{X(t_{n+1}) = i_{n+1} | X(t_n) = i_n\} \end{aligned} \quad (6.0.1)$$

则称 $\{X(t), t \geq 0\}$ 为 **连续参数马尔可夫链**(简称 **连续参数马氏链**). 若对于任意 $s, t \geq 0, i, j \in S$, 有

$$P\{X(s+t) = j | X(s) = i\} = P\{X(t) = j | X(0) = i\} \triangleq P_{ij}(t)$$

称 X 为 **齐次马氏链**, 本章仅讨论齐次马氏链. 称 $P(t) = (P_{ij}(t))(i, j \in S)$ 为 **转移概率矩阵**. 易知, 它满足

$$(P.1) \quad P_{ij}(t) \geq 0, \quad i, j \in S$$

$$(P.2) \quad \sum_{j \in S} P_{ij}(t) = 1, \quad i \in S$$

$$(P.3) \quad P_{ij}(s+t) = \sum_{k \in S} P_{ik}(s)P_{kj}(t), \quad s, t \geq 0, \quad i, j \in S$$

((P.3) 式通常称为 Chapman-Kolmogorov 方程)

$$(P.4) \quad P_{ij}(0) = \delta_{ij}, \quad \delta_{ii} = 1, \quad \delta_{ij} = 0 \quad (j \neq i).$$

本章还附加所谓标准性条件

$$(P.5) \quad \lim_{t \rightarrow 0} P_{ij}(t) = \delta_{ij}. \quad (\text{即 } P_{ij}(t) \text{ 在原点连续})$$

将 (P.3)(P.4)(P.5) 式写成矩阵形式:

$$P(s+t) = P(s)P(t)$$

$$P(0) = I, \quad \lim_{t \rightarrow 0} P(t) = I. \quad (I \text{ 为单位矩阵})$$

由于 $P(t)$ 满足 (P.1)~(P.4), 尤其满足附加连续性条件 (P.5), 使得 $P(t)$ 有许多很好的分析性质, 例如有

183

命题 若 $P(t) = (P_{ij}(t))$ 为标准性转移概率矩阵, 则对任意给定 $i \in S$, $P_{ij}(t)$ 在 $(0, \infty)$ 上一致连续, 且对 j 亦一致成立.

证 由 C-K 方程, 对 $\forall t, h > 0$

$$P_{ij}(t+h) - P_{ij}(t) = \sum_{k \neq i} P_{ik}(h)P_{kj}(t) - P_{ij}(t)[1 - P_{ii}(h)],$$

由此得

$$P_{ij}(t+h) - P_{ij}(t) \leq \sum_{k \neq i} P_{ik}(h)P_{kj}(t) \leq \sum_{k \neq i} P_{ik}(h) = 1 - P_{ii}(h),$$

以及

$$P_{ij}(t+h) - P_{ij}(t) \geq -P_{ij}(t)(1 - P_{ii}(h)) \geq -(1 - P_{ii}(h)),$$

从而有

$$|P_{ij}(t+h) - P_{ij}(t)| \leq 1 - P_{ii}(h)$$

类似地, 当 $h < 0$ 时, 有 $|P_{ij}(t) - P_{ij}(t+h)| \leq 1 - P_{ii}(h)$. \square

对于连续参数马氏链与离散参数马氏链, 由于它们都具有“马氏性”, 且状态空间均为可数集或有限集, 因而许多概念和性质有相同或相似之处. 例如状态分类, 状态相通, 平稳分布与极限分布等, 它们的联系及确切定义将在第 6.10 节介绍. 本章将着重讨论连续参数马氏链若干比较特殊的问题. 如: 转移率矩阵 (Q 矩阵) 及概率意义; Kolmogorov 向前向后微分方程, Fokker-Planck 方程; 生灭过程及应用; 强马氏性与嵌入马氏链; 可逆马氏链及在排队网络中的应用; 马氏更新过程.

§ 6.1 转移率矩阵 - Q 矩阵及其概率意义

在离散参数 MC 中, 我们知道由一步转移概率矩阵 $P = (P_{ij})$ 可以完全确定 n 步转移阵, 即有 $P^{(n)} = P^n = e^{n \cdot \ln P}$, 那么对连续参数 MC, 是否有类似的表达式, 即 $P(t) = e^{tQ}$ 呢? 其中 Q 为与 t 无关的实数矩阵, 假如上式存在, 则应有

$$P'(0) = \lim_{t \rightarrow 0} \frac{P(t) - P(0)}{t} = \lim_{t \rightarrow 0} \frac{e^{tQ} - I}{t} = Q$$

这就提示我们先要研究 $P(t)$ 在 $t = 0$ 的导数 (即变化率) 是否存在的问题, 先看最简单的一个例子, 再给出一般的结论.

例 设 $\{N(t), t \geq 0\}$ 为时齐 Poisson 过程, 参数为 λ . 因它是独立增量过程, 易知它是连续参数 MC, 则

$$\begin{aligned} P_{ij}(t) &= P\{N(s+t) = j | N(s) = i\} = P\{N(s+t) - N(s) = j - i\} \\ &= \begin{cases} \frac{(\lambda t)^{j-i}}{(j-i)!} e^{-\lambda t}, & j \geq i \geq 0 \\ 0, & 0 \leq j < i. \end{cases} \end{aligned}$$

6.1 转移率矩阵 $-Q$ 矩阵及其概率意义

故 $P'_{ij}(t)$ 存在, 且

$$q_{ij} \triangleq P'_{ij}(0) = \begin{cases} -\lambda, & j = i \geq 0 \\ \lambda, & j = i + 1, i \geq 0 \\ 0, & \text{其它.} \end{cases}$$

若令 $Q = (q_{ij})$, 可以验证 $P(t)$ 满足: $P(t) = e^{tQ}$.

对于一般马氏链, 有以下

定理 6.1.1 对 $i \in S$ 极限

$$q_i = -q_{ii} \triangleq \lim_{t \rightarrow 0} \frac{1 - P_{ii}(t)}{t} \quad (6.1.1)$$

存在, 但可能是无限.

证 首先, 由标准性条件 ($\lim_{t \rightarrow 0} P_{ii}(t) = 1$) 可知, 对任意固定 $t > 0$, 当 n 充分大时, 有 $P_{ii}(t/n) > 0$, 再由 C-K 方程 ($P_{ii}(s+t) = \sum_{k \in S} P_{ik}(s)P_{ki}(t) \geq P_{ii}(s)P_{ii}(t)$), 可得: $P_{ii}(t) \geq (P_{ii}(t/n))^n > 0$, 即 $P_{ii}(t) > 0, t \geq 0$, 故可以定义 $\phi(t) = -\ln P_{ii}(t)$. 它非负有限, 且由于 $P_{ii}(s+t) \geq P_{ii}(s)P_{ii}(t)$, 有 $\phi(s+t) \leq \phi(s) + \phi(t)$. 令 $q_i = \sup_{t>0} \frac{\phi(t)}{t}$, 下面要证 $\frac{\phi(t)}{t}$ 极限存在, 且即为其上确界. 显然

$$0 \leq q_i \leq \infty, \quad \limsup_{t \rightarrow 0} \frac{\phi(t)}{t} \leq q_i.$$

所以下只须证下极限 $\liminf_{t \rightarrow 0} \frac{\phi(t)}{t} \geq q_i$.

任给 $0 < h < t$, 取 n 使 $t = nh + \varepsilon, 0 \leq \varepsilon < h$, 得

$$\frac{\phi(t)}{t} \leq \frac{nh}{t} \cdot \frac{\phi(h)}{h} + \frac{\phi(\varepsilon)}{t}.$$

注意到, 当 $h \rightarrow 0^+$ 时, $\varepsilon \rightarrow 0, \frac{nh}{t} \rightarrow 1, \phi(\varepsilon) = -\ln P_{ii}(\varepsilon) \rightarrow 0$, 故 $\frac{\phi(t)}{t} \leq \liminf_{h \rightarrow 0} \frac{\phi(h)}{h}$, 得 $q_i \leq \liminf_{t \rightarrow 0} \frac{\phi(t)}{t}$, 从而 $q_i = \lim_{t \rightarrow 0} \frac{\phi(t)}{t}$.

由 $\phi(t)$ 定义得

$$\begin{aligned} \lim_{t \rightarrow 0} \frac{1 - P_{ii}(t)}{t} &= \lim_{t \rightarrow 0} \frac{1 - e^{-\phi(t)}}{\phi(t)} \cdot \frac{\phi(t)}{t} \\ &= q_i. \quad \square \end{aligned}$$

定理 6.1.2 对 $i, j \in S, j \neq i$ 极限

$$q_{ij} \triangleq P'_{ij}(0) = \lim_{t \rightarrow 0} \frac{P_{ij}(t)}{t} \quad (6.1.2)$$

存在且有限.

185

证 由标准性条件, 对任意 $0 < \varepsilon < \frac{1}{3}$, 存在 $0 < \delta < 1$, 使当 $0 < t \leq \delta$ 时, 有 $P_{ii}(t) > 1 - \varepsilon, P_{jj}(t) > 1 - \varepsilon, P_{ji}(t) < \varepsilon$.

下面要证: 对任意 $0 \leq h < t$, 只要 $t \leq \delta$, 则有

$$P_{ij}(h) \leq \frac{P_{ij}(t)}{n} \cdot \frac{1}{1-3\varepsilon} \quad (\text{a})$$

其中取 $n = \left[\frac{t}{h} \right]$ (即 n 为不超过 $\frac{t}{h}$ 的最大整数), 记

$$\begin{cases} {}_jP_{ik}(h) = P_{ik}(h) \\ {}_jP_{ik}(mh) = \sum_{r \neq j} {}_jP_{ir}((m-1)h)P_{rk}(h). \end{cases}$$

其中 ${}_jP_{ik}(mh)$ 表示从 i 出发, 在时刻 $h, 2h, \dots, (m-1)h$ 未到达 j 且在 mh 时刻到达 k 的概率, 当 $h < t \leq \delta$ 时, 有

$$\begin{aligned} \varepsilon > 1 - P_{ii}(t) &= \sum_{k \neq i} P_{ik}(t) \\ &\geq P_{ij}(t) \\ &\geq \sum_{m=1}^n {}_jP_{ij}(mh)P_{jj}(t-mh) \\ &\geq (1-\varepsilon) \sum_{m=1}^n {}_jP_{ij}(mh). \end{aligned}$$

得

$$\sum_{m=1}^n {}_jP_{ij}(mh) \leq \frac{\varepsilon}{1-\varepsilon}.$$

又由

$$P_{ii}(mh) = {}_jP_{ii}(mh) + \sum_{l=1}^{m-1} {}_jP_{ij}(lh)P_{ji}((m-1)h),$$

得

$${}_jP_{ii}(mh) \geq P_{ii}(mh) - \sum_{l=1}^{m-1} {}_jP_{ij}(lh) \geq 1 - \varepsilon - \frac{\varepsilon}{1-\varepsilon}.$$

故

$$\begin{aligned} P_{ij}(t) &\geq \sum_{m=1}^n {}_jP_{ii}((m-1)h)P_{ij}(h)P_{jj}(t-mh) \\ &\geq n \left(1 - \varepsilon - \frac{\varepsilon}{1-\varepsilon} \right) P_{ij}(h)(1-\varepsilon) \\ &\geq n(1-3\varepsilon)P_{ij}(h). \end{aligned}$$

(a) 式得证. (a) 式两边除以 h (注意, 当 $h \rightarrow 0$ 时 $nh \rightarrow t$), 得

$$\limsup_{h \rightarrow 0} \frac{P_{ij}(h)}{h} \leq \frac{1}{1-3\varepsilon} \frac{P_{ij}(t)}{t} < \infty.$$

6.1 转移率矩阵 -Q 矩阵及其概率意义

再令 $t \rightarrow 0$, 有

$$\limsup_{h \rightarrow 0} \frac{P_{ij}(h)}{h} \leq \frac{1}{1-3\varepsilon} \liminf_{t \rightarrow 0} \frac{P_{ij}(t)}{t}.$$

再令 $\varepsilon \rightarrow 0$, 定理得证. □

推论 1 对任意 $i \in S$

$$0 \leq \sum_{j \neq i} q_{ij} \leq q_i \quad (6.1.3)$$

证 由 $\sum_{j \in S} P_{ij}(t) = 1$, 得 $\frac{1-P_{ii}(t)}{t} = \sum_{j \neq i} \frac{P_{ij}(t)}{t}$.

令 $t \rightarrow 0^+$, 上式两边取下极限, 并由 Fatou 引理及 (6.1.1), (6.1.2) 得

$$q_i = \lim_{t \rightarrow 0} \sum_{j \neq i} \frac{P_{ij}(t)}{t} \geq \sum_{j \neq i} \lim_{t \rightarrow 0} \frac{P_{ij}(t)}{t} = \sum_{j \neq i} q_{ij}. \quad \square$$

注意到当 S 为有限集时, 上式不等式化为等式. 故有

推论 2 当 S 为有限状态空间时, $\forall i \in S$, 有

$$0 \leq \sum_{j \neq i} q_{ij} = q_i < \infty. \quad (6.1.4)$$

记 $Q = (q_{ij})$ (其中 $q_{ii} = -q_i$), 称 Q 为 $\{X(t), t \geq 0\}$ 的 **转移率矩阵** (或称 **密度矩阵**).

若转移率矩阵 $Q = (q_{ij})$ 满足: $\forall i \in S, \sum_{j \neq i} q_{ij} = q_i < \infty$, 称 Q 为 **保守**.

由推论 2 知, 当 S 为有限集时, Q 必保守.

为了解释 $Q = (q_{ij})$ 的概率意义, 我们令

$$\tau_1 = \inf\{t : t > 0, X(t) \neq X(0)\}.$$

τ_1 表示逗留在初始状态的时间 (或首次离开初始状态的时间). τ_1 的概率特性与 $Q = (q_{ij})$ 有何关系呢?

定理 6.1.3 设马氏链 $X = \{X(t), t \geq 0\}$ 轨道右连续, 则对 $i \in S, t \geq 0$, 有

$$P(\tau_1 > t | X(0) = i) = \exp(-q_i t). \quad (6.1.5)$$

证 由轨道右连续, 得

$$P(\tau_1 > t | X(0) = i) = P[(X(u) = i, 0 \leq u \leq t | X(0) = i)]$$

所以, 首先要将不可列事件转化为可列事件运算. 令

187

$$B \triangleq \{\omega : X(u) = i, 0 \leq u \leq t\} = \bigcap_{0 \leq u \leq t} \{\omega : X(u) = i\}.$$

将 $[0, t]$ 区间 2^n 等分, 记

$$\begin{aligned} A_n &\triangleq \{\omega : X\left(\frac{k}{2^n} \cdot t\right) = i, k = 0, 1, 2, \dots, 2^n\} \\ &= \bigcap_{k=0}^{2^n} \{\omega : X\left(\frac{k}{2^n} \cdot t\right) = i\}. \end{aligned}$$

因为 $A_{n+1} \subset A_n$, 所以记 $A \triangleq \bigcap_{n=1}^{\infty} A_n = \lim_{n \rightarrow \infty} A_n$.

显然 $B \subset A$. 还可证明 $A \subset B$ (至多差一个 0 测集). 所以 $A \triangle B = (A \setminus B) \cup (B \setminus A) = \phi$. 故

$$\begin{aligned} P(\tau_1 > t | X(0) = i) &= P(X(u) = i, 0 \leq u \leq t | X(0) = i) \\ &= P(B | X(0) = i) \\ &= P(A | X(0) = i) \\ &= \lim_{n \rightarrow \infty} P(A_n | X(0) = i) \\ &= \lim_{n \rightarrow \infty} P\left(X\left(\frac{k}{2^n} \cdot t\right) = i, k = 0, 1, 2, \dots, 2^n | X(0) = i\right) \\ &= \lim_{n \rightarrow \infty} \left(P_{ii}\left(\frac{t}{2^n}\right)\right)^{2^n} \quad (\text{马氏性}) \\ &= \lim_{n \rightarrow \infty} \exp\left\{2^n \ln P_{ii}\left(\frac{t}{2^n}\right)\right\} \\ &= \lim_{n \rightarrow \infty} \exp\left\{\frac{\ln[1 - q_i\left(\frac{t}{2^n}\right) + o\left(\frac{t}{2^n}\right)]}{\frac{1}{2^n}(-q_i t)}(-q_i t)\right\} \\ &= \exp(-q_i t). \quad (\text{因为由 } q_i \text{ 的定义知 } P_{ii}(t) = 1 - q_i + o(t)) \quad \square \end{aligned}$$

这说明系统逗留在 $X(0) = i$ 状态的时间 τ_1 是服从参数为 q_i 的指数分布的, 显然

$$E[\tau_1 | X(0) = i] = q_i^{-1}.$$

可见, q_i 决定了过程 $\{X(t), t \geq 0\}$ 停留在 $X(0) = i$ 的平均逗留时间, 它刻画了过程从 i 出发的转移速率. 分三种情形:

1° $q_i = 0$, 称 i 为 **吸收状态**. 这是因为 $(\tau_1 = \infty) = \bigcap_{n=1}^{\infty} (\tau_1 > n)$, $P(\tau_1 = \infty | X(0) = i) = \lim_{n \rightarrow \infty} P(\tau_1 > n | X(0) = i) = 1$. 即从 i 出发, 过程以概率 1 永远停留在 i 状态.

2° $q_i = \infty$, 称 i 为 **瞬时状态**. 此时 $P[\tau_1 = 0 | X(0) = i] = \lim_{n \rightarrow \infty} P[\tau_1 \leq \frac{1}{n} | X(0) = i] = 1$. 这说明 X 在 i 状态几乎不停留立即跳到别的状态.

3° $0 < q_i < \infty$, 称 i 为 **逗留状态**. 这时过程停留在状态 i 若干时间后跳到别的状态, 停留时间服从指数分布.

定理 6.1.4 设马氏链 $X = \{X(t), t \geq 0\}$ 轨道右连续, 且 $0 < q_i < \infty$. 则对 $t \geq 0$,

6.1 转移率矩阵 -Q 矩阵及其概率意义

$j \neq i$ 有

$$P[\tau_1 \leq t, X(\tau_1) = j | X(0) = i] = \frac{q_{ij}}{q_i} [1 - \exp(-q_i t)]. \quad (6.1.6)$$

$$P[X(\tau_1) = j | X(0) = i] = \frac{q_{ij}}{q_i}. \quad (6.1.7)$$

证 先进行事件分解,

$$(\tau_1 \leq t, X(\tau_1) = j) = \bigcup_{0 \leq u \leq t} (\tau_1 = u, X(\tau_1) = j)$$

与定理 6.1.3 的证明类似, 下面也是采用将不可列事件化为可列事件运算. 令

$$B = \{\tau_1 \leq t, X(0) = i, X(\tau_1) = j\}, \quad A_n = \bigcup_{0 \leq k \leq 2^n} \{X(\frac{vt}{2^n}) = i, 0 \leq v \leq k, X(\frac{kt}{2^n}) = j\}$$

因为 $A_n \subset A_{n+1}$, 所以 $A \triangleq \bigcup_{n=1}^{\infty} A_n = \lim_{n \rightarrow \infty} A_n$, 且 $B \cup N = A$, 其中 N 是概率为 0 的事件, 即 $P(N) = 0$.

由此得

$$\begin{aligned} & P[\tau_1 \leq t, X(\tau_1) = j | X(0) = i] \\ &= \lim_{n \rightarrow \infty} \sum_{k=1}^{2^n} P\left\{X\left(\frac{v}{2^n}t\right) = i, 0 \leq v < k, X\left(\frac{k}{2^n}t\right) = j | X(0) = i\right\} \\ &= \lim_{n \rightarrow \infty} \sum_{k=1}^{2^n} \left(P_{ii}\left(\frac{t}{2^n}\right)\right)^{k-1} \cdot P_{ij}\left(\frac{t}{2^n}\right) \quad (\text{马氏性}) \\ &= \lim_{n \rightarrow \infty} \frac{1 - (P_{ii}(\frac{t}{2^n}))^{2^n}}{1 - P_{ii}(\frac{t}{2^n})} \cdot P_{ij}\left(\frac{t}{2^n}\right) \\ &= \lim_{n \rightarrow \infty} \left\{[1 - (P_{ii}(t/2^n))^{2^n}] \cdot \frac{P_{ii}(t/2^n)/(t/2^n)}{(1 - P_{ii}(t/2^n))/(t/2^n)}\right\} \quad (\text{由 (6.1.1) 及 (6.1.2) 式}) \\ &= [1 - \exp(-q_i t)] q_{ij} / q_i. \end{aligned}$$

(6.1.6) 式得证. 上式中令 $t \rightarrow \infty$ 即得 (6.1.7). □

推论 若马氏过程 $\{X(t), t \geq 0\}$ 轨道右连续, 且 $Q = (q_{ij})$ 为保守的, $0 < q_i < \infty$, $i \in S$, 则关于 $X(0) = i$, τ_1 与 $X(\tau_1)$ 条件独立.

证 由 (6.1.5) ~ (6.1.7) 式, 对 $\forall t \geq 0, j \in S$, 有 $P(\tau_1 \leq t, X(\tau_1) = j | X(0) = i) = P(\tau_1 \leq t | X(0) = i) = P(X(\tau_1) = j | X(0) = i)$ 及保守性, 即得 τ_1 与 $X(\tau_1)$ 关于 $X(0) = i$ 条件独立. □

从上节讨论可知, 由马氏链 $X = \{X(t), t \geq 0\}$ 的转移概率矩阵 $P(t) = (P_{ij}(t))$ 可唯一地决定其密度矩阵 $P'(0) = Q = (q_{ij})$, 很自然地我们要问: 反之, 给定一个密度矩阵 $Q = (q_{ij})$, 是否可唯一地决定一转移概率矩阵 $P(t) = (P_{ij}(t))$, 使其满足 $P(t)$ 的性质 (P.1)~(P.5), 且 $P'(0) = Q$? 为此, 我们先引入若干概念, 然后着重讨论在 S 为有限集时 $P(t)$ 与 Q 的关系, 并简介几种由 Q 求 $P(t)$ 的方法.

定义 一个矩阵 $Q = (q_{ij})$ 称为 Q 矩阵, 如满足:

$$1^\circ \quad q_{ii} \triangleq -q_i \leq 0 (\text{可以取 } -\infty);$$

$$2^\circ \quad 0 \leq q_{ij} < +\infty, j \neq i;$$

$$3^\circ \quad \sum_{j \neq i} q_{ij} \leq q_i.$$

称 Q 矩阵为 **保守**, 若 $\forall i \in S, \sum_{j \neq i} q_{ij} = q_i < \infty$. □

由上节可知, 当 $P(t)$ 为标准转移阵时, 其密度矩阵 $P'(0) = (P'_{ij}(0)) = (q_{ij})$ 为 Q 矩阵, 且当 S 为有限集时, $P'(0)$ 为保守 Q 矩阵.

定义 对给定 Q 矩阵 $Q = (q_{ij})$, 若有马氏链 $X = \{X(t), t \geq 0\}$ 的转移阵 $P(t) = (P_{ij}(t))$ 满足 $P'(t)|_{t=0} = Q$, 则称此马氏链 X 为 (Q 矩阵 Q 的) Q 过程. □

定理 6.2.1 设 $MC\{X(t), t \geq 0\}$, $P(t) = (P_{ij}(t))$, $Q = (q_{ij}) = P'(0)$. 当 S 为有限集时, 有

$$P'(t) = P(t)Q \quad (6.2.1)$$

$$P'(t) = QP(t) \quad (6.2.2)$$

证 由 C-K 方程 $P(t+h) = P(t)P(h) = P(h)P(t)$, 有

$$\frac{P(t+h) - P(t)}{h} = P(t) \left[\frac{P(h) - I}{h} \right] = \left[\frac{P(h) - I}{h} \right] P(t) \quad (6.2.3)$$

令 $h \rightarrow 0$, 两边取极限, 注意到 S 为有限集, 即得 (6.2.1) (6.2.2). □

(6.2.1) 和 (6.2.2) 式称为 k 氏向前向后微分方程. 其分量形式

$$P'_{ij}(t) = -q_j P_{ij}(t) + \sum_{k \neq j} P_{ik}(t) q_{kj} \quad (6.2.1a)$$

$$P'_{ij}(t) = -q_i P_{ij}(t) + \sum_{k \neq i} q_{ik} P_{kj}(t) \quad (6.2.1a)$$

以上给出 S 有限集时, $P(t)$ 与 Q 的关系. 当 $Q = (q_{ij})$ 为已知的保守 Q 矩阵, 且 S 为有限集时容易验证常微分方程组

$$\begin{cases} P'(t) = P(t)Q = QP(t) \\ P(0) = I \end{cases}$$

存在满足 (P.1)~(P.5) 条件的转移概率矩阵的唯一解

$$P(t) = e^{Qt} \triangleq \sum_{k=0}^{\infty} \frac{t^k}{k!} Q^k.$$

同时, $P'(0) = Q$.

对于 S 为可数状态时, 向前方程与向后方程不一定成立, 但由 (6.2.3) 式及 Fatou 引理, 有

$$P'(t) \geq P(t)Q, \quad P'(t) \geq QP(t).$$

定理 6.2.2 当 S 可数, $Q = (q_{ij})$ 为保守 Q 矩阵时, 则向后方程 $P'(t) = QP(t)$ 成立.

为了证明该定理, 先不加证明的给出一个引理

引理 设 $f(x)$ 为 (a, b) 上的连续函数, 且 $f(x)$ 在 (a, b) 中有连续的右导数, 则 $f(x)$ 在 (a, b) 上可导.

定理 6.2.2 的证明 由 C-K 方程, $h > 0$ 时

$$\frac{p_{ij}(t+h) - p_{ij}(t)}{h} = \frac{p_{ij}(h) - 1}{h} p_{ij}(t) + \sum_{k \neq i} \frac{p_{ik}(h)}{h} p_{kj}(t). \quad (6.2.4)$$

由 Fatou 引理, 有

$$\liminf_{h \rightarrow 0^+} \sum_{k \neq i} \frac{p_{ik}(h)}{h} p_{kj}(t) \geq \sum_{k \neq i} q_{ik} p_{kj}(t). \quad (6.2.5)$$

另一方面, 对 $N > i$

$$\begin{aligned} \limsup_{h \rightarrow 0^+} \sum_{k \neq i} \frac{p_{ik}(h)}{h} p_{kj}(t) &\leq \limsup_{h \rightarrow 0^+} \left[\sum_{k \neq i, k < N} \frac{p_{ik}(h)}{h} p_{kj}(t) + \sum_{k \geq N} \frac{p_{ik}(h)}{h} \right] \\ &= \limsup_{h \rightarrow 0^+} \left[\sum_{k \neq i, k < N} \frac{p_{ik}(h)}{h} p_{kj}(t) + \frac{1 - p_{ii}(h)}{h} - \sum_{k \neq i, k < N} \frac{p_{ik}(h)}{h} \right] \\ &= \sum_{k \neq i, k < N} q_{ik} p_{kj}(t) + q_i - \sum_{k \neq i, k < N} q_{ik}, \end{aligned}$$

令 $N \rightarrow \infty$, 由保守性得

$$\limsup_{h \rightarrow 0^+} \sum_{k \neq i} \frac{p_{ik}(h)}{h} p_{kj}(t) \leq \sum_{k \neq i} q_{ik} p_{kj}(t). \quad (6.2.6)$$

由 (6.2.5) 及 (6.2.6) 得

$$\limsup_{h \rightarrow 0^+} \sum_{k \neq i} \frac{p_{ik}(h)}{h} p_{kj}(t) = \sum_{k \neq i} q_{ik} p_{kj}(t).$$

再由 (6.2.4) 得

$$\lim_{h \rightarrow 0^+} \frac{p_{ij}(t+h) - p_{ij}(t)}{h} = \sum_k q_{ik} p_{kj}(t).$$

仍由保守性知, 上式右边的级数关于 t 一致收敛, 因此是 t 的连续函数, 故由引理的定理.

让我们考虑 $X(t)$ 在 t 时刻的概率分布, 记 $P_j(t) = P(X(t) = j)$, 显然

$$P_j(t) = \sum_{i \in S} P_i(0) P_{ij}(t).$$

我们有

定理 6.2.3 当 S 为有限集时, 下列 Fokker-Planck 方程成立

$$P'_j(t) = -P_j(t)q_j + \sum_{k \neq j} P_k(t)q_{kj}. \quad (6.2.7)$$

证 由 (6.2.1a) 两边同乘以 $P_i(0)$ 并对 i 求和即得 (6.2.7) 式. \square

为了解决具体问题, 先回顾一下平稳分布和极限分布的概念. 若一概率分布 $\{\pi_j, j \in S\}$ 满足 $\pi_j = \sum_{i \in S} \pi_i P_{ij}(t) (\forall j \in S, t \geq 0)$, 则称 $\{\pi_j, j \in S\}$ 为平稳分布. 与离散时间 MC 有相类似的结果: 当马氏链 $X = \{X(t), t \geq 0\}$ 为不可约遍历链时, 则必存在唯一的平稳分布 $\{\pi_j, j \in S\}$, 且它就等于极限分布, 即 $\pi_j = P_j (j \in S)$. 从而有以下定理.

定理 6.2.4 当 S 为有限集且为不可约链时, 其平稳分布 $\pi = (\pi_j, j \in S)$ 存在, 且满足: $\pi_j q_j = \sum_{k \neq j} \pi_k q_{kj}$.

证明 由于 $\pi_j = \lim_{t \rightarrow \infty} P_{ij}(t)$, 对 (6.2.4) 式两边对 t 取极限, 左边 $= \lim_{t \rightarrow \infty} P'_j(t) = P'_j = \pi'_j = 0$, 右边 $= -\pi_j q_j + \sum_{k \neq j} \pi_k q_{kj}$. 从而 $\pi_j q_j = \sum_{k \neq j} \pi_k q_{kj}$. \square

有了以上理论上的准备, 我们可以进一步讨论由密度矩阵 Q 求解转移概率矩阵 $P(t)$ 的几种方法.

1° 当 S 有限时, 我们可以利用分析的方法求解向前向后微分方程.

例 1 设某触发器状态只有二个, $S = \{0, 1\}$, “0”表示工作态, “1”表示失效态. $X(t)$ 表示 t 时触发器状态. 已知其状态转移具有马氏性. 即 $X = \{X(t), t \geq 0\}$ 为 MC, 且 $P_{01}(t) = \lambda t + o(t)$, $P_{10}(t) = \mu t + o(t)$, 得

$$Q = \begin{pmatrix} -\lambda & \lambda \\ \mu & -\mu \end{pmatrix}.$$

试求 $P(t) = (P_{ij}(t))$ (设 $P_0(0) = 1$).

解 由向后方程得:

$$\begin{pmatrix} P'_{00}(t) \\ P'_{10}(t) \end{pmatrix} = \begin{pmatrix} -\lambda & \lambda \\ \mu & -\mu \end{pmatrix} \cdot \begin{pmatrix} P_{00}(t) \\ P_{10}(t) \end{pmatrix}.$$

192

经适当简化后有

$$\mu P'_{00}(t) + \lambda P'_{10}(t) = 0.$$

两边积分得

$$\mu P_{00}(t) - \mu + \lambda P_{10}(t) = 0.$$

再由初始条件 $P_{00}(0) = 1$, $P_{10}(0) = 0$, 于是有

$$\begin{cases} P'_{00}(t) + (\lambda + \mu)P_{00}(t) = \mu \\ P_{00}(0) = 1. \end{cases}$$

采用解常系数微分方程常用的常数变易法, 解之得:

$$P_{00}(t) = \frac{\mu}{\lambda + \mu} + \frac{\lambda}{\lambda + \mu} e^{-(\lambda + \mu)t}.$$

从而

$$\begin{aligned} P_{10}(t) &= \frac{\mu}{\lambda + \mu} - \frac{\mu}{\lambda + \mu} e^{-(\lambda + \mu)t}, \\ P_{01}(t) &= \frac{\lambda}{\lambda + \mu} - \frac{\lambda}{\lambda + \mu} e^{-(\lambda + \mu)t}, \\ P_{11}(t) &= \frac{\lambda}{\lambda + \mu} + \frac{\mu}{\lambda + \mu} e^{-(\lambda + \mu)t}. \end{aligned}$$

再由 $P_0(0) = P(X(0) = 0) = 1$, 得

$$P_0(t) = P_0(0)P_{00}(t) = \frac{\mu}{\lambda + \mu} + \frac{\lambda}{\lambda + \mu} e^{-(\lambda + \mu)t},$$

$$P_1(t) = P_{01}(t) = \frac{\lambda}{\lambda + \mu} - \frac{\lambda}{\lambda + \mu} e^{-(\lambda + \mu)t}.$$

再求平稳分布 (也是极限分布), 得:

$$P_0 = \lim_{t \rightarrow \infty} P_{00}(t) = \frac{\mu}{\lambda + \mu}$$

及

$$P_1 = \lim_{t \rightarrow \infty} P_{01}(t) = \frac{\lambda}{\lambda + \mu}.$$

2° 当 S 为可列集时, 若已知 $Q = (q_{ij})$, 欲求满足向前向后方程 $P(t)$ 的解, 可用概率构造法求之, 这里仅以 Q 矩阵为保守时为例, 求解向后方程. 令

$${}_n P_{ij}(t) = P[X(u) \text{ 在 } u \in [0, t] \text{ 恰有 } n \text{ 次跳跃, 且 } X(t) = j | X(0) = i]$$

则首先易得

$${}_0 P_{ij}(t) = \delta_{ij} e^{-q_i t},$$

再由全概率公式可求递推关系:

$$\begin{aligned}
 {}_{n+1}P_{ij}(t) &= P[n+1 \text{ 次跳到 } j | X(0) = i] \\
 &= \int_0^t \sum_{(k \neq i)} P(X(\tau_{n+1}) = j, \tau_{n+1} \leq t | X(0) = i, \tau_1 = s, X(\tau_1) = k) dP(\tau_1 \leq s, \\
 &\quad X(\tau_1) = k | X(0) = i) (\text{对 } \tau_1 \text{ 及 } X(\tau_1) \text{ 用全概率公式}) \\
 &= \int_0^t \sum_{(k \neq i)} P(X(\tau_n) = j, \tau_n \leq t - s | X(0) = k) \frac{q_{ik}}{q_i} \cdot q_i e^{-q_i s} ds \\
 &\quad (\text{利用 § 6.4 中强马氏性}) \\
 &= \int_0^t \sum_{(k \neq i)} {}_n P_{kj}(t-s) q_{ik} e^{-q_i s} ds \\
 &= \sum_{(k \neq i)} \int_0^t {}_n P_{kj}(t-s) q_{ik} e^{-q_i s} ds
 \end{aligned}$$

以上递推式也可有如下直观概率解释:

$${}_{n+1}P_{ij}(t) = \sum_{(k \neq i)} \int_0^t (e^{-q_i s}) \cdot (q_{ik} ds) \cdot ({}_n P_{kj}(t-s))$$

其中, $(e^{-q_i s})$ 表示在 i 状态逗留时间 s , $(q_{ik} ds)$ 表示在 ds 时间内发生跳跃的概率 (即 $P(X(\tau_1) = j, \tau_1 \leq ds | X(0) = i) = \frac{q_{ij}}{q_i}(1 - e^{-q_i ds}) = \frac{q_{ij}}{q_i}(1 - (1 - q_i ds)) = q_{ij} ds$), $({}_n P_{kj}(t-s))$ 表示在余下时间 $(t-s)$ 内发生 n 次跳跃, 最终转移到 j 的概率. 最后, 对 k 求和, 对时间 s 从 0 到 t 积分.

有以上递推公式后, 令 $f_{ij}(t) = \sum_{n=0}^{\infty} {}_n P_{ij}(t)$, 则可验证 $F(t) = (f_{ij}(t))$ 是向后方程的最小非负解. 这启示我们: 可以籍助于概率方法求某一类微分方程的解.

3° 用拉普拉斯 (Laplace) 变换求解向前向后微分方程. 它将这方程转化成代数方程, 以便于用代数方法作处理. 为此首先叙述一些必需的拉普拉斯变换的基本知识.

引理 6.2.5 设 $[0, \infty]$ 上的函数 $f(t)$ 的拉普拉斯变换为 $\phi(\lambda)$, 则

$$g(t) = \int_0^t e^{-q(t-s)} f(s) ds, \quad q > 0$$

的拉普拉斯变换为 $\frac{\phi(\lambda)}{\lambda + q}$.

证 直接计算即可:

$$\begin{aligned}
 \int_0^{\infty} e^{-\lambda t} dt \int_0^t e^{-q(t-s)} f(s) ds &= \int_0^{\infty} e^{qs} f(s) ds \int_s^{\infty} e^{-(\lambda+q)t} dt \\
 &= \frac{1}{\lambda + q} \int_0^{\infty} e^{-\lambda s} f(s) ds \\
 &= \frac{\phi(\lambda)}{\lambda + q}.
 \end{aligned}$$

在上述计算过程中以 $|f(s)|$ 代 $f(s)$, 由 $\int_0^\infty e^{-\lambda s} |f(s)| ds < \infty$ 可知, 在计算中交换积分号是可行的, 且 $\int_0^\infty e^{-\lambda t} |g(t)| dt < \infty$. \square

对于转移概率矩阵 $P(t)$, 由于 $P_{ij}(t)$ 是 $[0, \infty)$ 上的有界连续函数, 它有拉普拉斯变换, 记为

$$r_{ij}(\lambda) = \int_0^\infty e^{-\lambda t} P_{ij}(t) dt, \quad \lambda > 0, \quad i, j \in S.$$

令

$$R(\lambda) = (r_{ij}(\lambda)), \quad \lambda > 0, \quad i, j \in S.$$

它们称作转移概率函数的 **预解式**, 有以下性质:

定理 6.2.5 对一切 $i, j \in S$ 及 $\lambda, \mu > 0$

$$(1) \quad r_{ij}(\lambda) > 0;$$

$$(2) \quad \lambda \sum_{j \in S} r_{ij}(\lambda) = 1;$$

$$(3) \quad r_{ij}(\lambda) - r_{ij}(\mu) + (\lambda - \mu) \sum_{k \in S} r_{ik}(\lambda) r_{kj}(\mu) = 0;$$

$$(4) \quad \lim_{\lambda \rightarrow \infty} \lambda r_{ij}(\lambda) = \delta_{ij}.$$

或写成以下简洁的矩阵形式:

$$(1') \quad R(\lambda) \geq 0;$$

$$(2') \quad \lambda R(\lambda) e = e(e = (1, 1, \dots, 1)^T);$$

$$(3') \quad R(\lambda) - R(\mu) + (\lambda - \mu) R(\lambda) R(\mu) = 0;$$

$$(4') \quad \lim_{\lambda \rightarrow \infty} \lambda R(\lambda) = I.$$

称 (1')~(4') 为 **预解方程**.

证 (1), (2) 容易证, 留给读者练习, 这里只证 (3) 与 (4).

(3) 可由 C-K 方程用如下方法推得.

$$\begin{aligned} \int_0^\infty \int_0^\infty e^{-(\lambda t + \mu s)} P_{ij}(t+s) dt ds &= \int_0^\infty \int_0^\infty e^{-(\lambda t + \mu t)} \sum_k P_{ik}(t) P_{kj}(s) dt ds = \sum_k r_{ik}(\lambda) r_{kj}(\mu). \end{aligned} \quad (6.2.8)$$

现在不妨设 $\lambda > \mu$. 注意到

$$\begin{aligned} \int_0^\infty e^{-\mu s} P_{ij}(t+s) ds &= \int_t^\infty e^{-\mu(u-t)} P_{ij}(u) du \\ &= e^{\mu t} \left\{ \int_0^\infty e^{-\mu u} P_{ij}(u) du - \int_0^t e^{-\mu u} P_{ij}(u) du \right\} \\ &= e^{\mu t} r_{ij}(\mu) - \int_0^t e^{\mu(t-u)} P_{ij}(u) du, \end{aligned}$$

我们有

$$\begin{aligned}
 \int_0^\infty \int_0^\infty e^{-(\lambda t + \mu s)} P_{ij}(t+s) dt ds &= \int_0^\infty e^{-\lambda t} dt \int_0^\infty e^{-\mu s} P_{ij}(t+s) ds \\
 &= r_{ij}(\mu) \int_0^\infty e^{-(\lambda-\mu)t} dt - \int_0^\infty e^{-\mu u} P_{ij}(u) du \int_0^\infty e^{-(\lambda-\mu)t} dt \\
 &= \frac{r_{ij}(\mu)}{\lambda-\mu} - \int_0^\infty e^{-\lambda u} P_{ij}(u) \frac{du}{\lambda-\mu} \\
 &= -\frac{1}{\lambda-\mu} \{r_{ij}(\lambda) - r_{ij}(\mu)\}.
 \end{aligned} \tag{6.2.9}$$

易见, 若 $\mu > \lambda$, 我们可得到同样的结果. 有 (6.2.8) 和 (6.2.9) 式即得 (3).

(4) 可由连续性条件推得. 事实上,

$$\begin{aligned}
 \lambda r_{ij}(\lambda) &= \lambda \int_0^\infty e^{-\lambda t} P_{ij}(t) dt = \int_0^\infty e^{-u} P_{ij}(u/\lambda) du, \\
 \lim_{\lambda \rightarrow \infty} P_{ij}(u/\lambda) &= \delta_{ij}, \quad \int_0^\infty e^{-u} du = 1,
 \end{aligned}$$

由控制收敛定理即得 (4). □

下面引入向后方程的积分形式:

$$P_{ij}(t) = \delta_{ij} e^{-q_i t} + \sum_{k \neq i} \int_0^t e^{-q_i(t-s)} q_{ik} P_{kj}(s) ds. \tag{6.2.10}$$

实际上, 由向后方程 $P'_{ij}(t) = \sum_k q_{ik} P_{kj}(t)$, 可得:

$$\begin{aligned}
 P_{ij}(t) - \delta_{ij} e^{-q_i t} &= \int_0^t d[P_{ij}(s) e^{-q_i(t-s)}] \\
 &= \int_0^t e^{-q_i(t-s)} P'_{ij}(s) ds + \int_0^t q_i e^{-q_i(t-s)} P_{ij}(s) ds \\
 &= \int_0^t e^{-q_i(t-s)} (q_{ii} P_{ij}(s) + \sum_{k \neq i} q_{ik} P_{kj}(s)) ds + \int_0^t (-q_{ii}) e^{-q_i(t-s)} P_{ij}(s) ds \\
 &= \sum_{k \neq i} \int_0^t e^{-q_i(t-s)} q_{ik} P_{kj}(s) ds.
 \end{aligned}$$

即得 (6.2.8). 对其取拉普拉斯变换, 利用引理 (6.2.4), 得到预解式满足的向后方程 (线性代数方程组)

$$r_{ij}(\lambda) = \sum_{k \neq i} \frac{q_{ik}}{\lambda + q_i} r_{kj}(\lambda) + \frac{\delta_{ij}}{\lambda + q_i}, \quad \lambda > 0, \quad i, j \in S.$$

类似, 也可得到向前方程的积分形式和向前线性代数方程组. 这样, 解微分方程就转化成求解线性代数方程组了.

§ 6.3 生灭过程

这一节转到讨论一类特殊的马氏链—生灭过程，它在排队系统，可靠性理论，生物，医学，经济管理，物理，通讯，交通等方面有广泛的应用。而且它的理论成果较为系统，成熟和深入。

定义 设马氏链 $X = \{X(t), t \geq 0\}$ ，状态空间 $S = \{0, 1, 2, \dots\}$ ，若 $P(t) = (P_{ij}(t))$ 满足：当 h 充分小时，

$$\begin{cases} P_{i,i+1}(h) = \lambda_i h + o(h), & \lambda_i > 0, i \geq 0 \\ P_{i,i-1}(h) = \mu_i h + o(h), & \mu_i > 0, i \geq 1 \\ P_{ii}(h) = 1 - (\lambda_i + \mu_i)h + o(h), & \mu_0 = 0, i \geq 0 \\ \sum_{|j-i| \geq 2} P_{ij}(h) = o(h), & i \geq 0. \end{cases} \quad (6.3.1)$$

称 X 为 **生灭过程**。 □

(6.3.1) 表示，当 h 充分小时，状态转移有三种可能： $i \rightarrow i+1$, $i \rightarrow i-1$, $i \rightarrow i$ 。这个特性是许多生物群体，粒子裂变，信号计数等的共同特点，因而可作为这一类物理自然现象的数学模型。

由 (6.3.1) 式知： $q_i = (\lambda_i + \mu_i)$, $q_{i,i+1} = \lambda_i$, $q_{i,i-1} = \mu_i$ ，其它 $q_{ij} = 0$ ，即 $Q = (q_{ij})$ 表示为：

$$Q = \begin{bmatrix} -\lambda_0 & \lambda_0 & 0 & 0 & 0 & 0 & \cdots & \cdots \\ \mu_1 & -(\lambda_1 + \mu_1) & \lambda_1 & 0 & 0 & 0 & \cdots & \cdots \\ 0 & \mu_2 & -(\lambda_2 + \mu_2) & \lambda_2 & 0 & 0 & \cdots & \cdots \\ 0 & \ddots & & & & & & \\ \vdots & & & 0 & \mu_i & -(\lambda_i + \mu_i) & \lambda_i & 0 & \cdots \\ \vdots & & & & 0 & & \ddots & & \cdots \\ 0 & & & & & & \ddots & \ddots & \ddots \end{bmatrix} \quad (6.3.2)$$

形如 (6.3.2) 的矩阵，称作生灭过程 Q 矩阵。显然，它是保守 Q 矩阵，且在 $\lambda_i > 0 (i \geq 0)$, $\mu_i > 0 (i \geq 1)$ 时，有 $i-1 \leftrightarrow i \leftrightarrow i+1 (i \geq 1)$ ，可知对 $\forall i, j \in S$, $i \leftrightarrow j$ ，从而这样的生灭过程是不可约链，同时有以下

定理 6.3.1 若 X 为生灭过程，则 $P(t)$, Q 满足向前向后方程：

$$P'_{ij}(t) = -P_{ij}(t)(\lambda_j + \mu_j) + P_{i,j-1}(t)\lambda_{j-1} + P_{i,j+1}(t)\mu_{j+1} \quad (6.3.3)$$

$$P'_{ij}(t) = -(\lambda_i + \mu_i)P_{ij}(t) + \lambda_i P_{i+1,j}(t) + \mu_i P_{i-1,j}(t) \quad (6.3.4)$$

且 $\{P_j(t), j \in S\}$ 满足 Fokker-Planck 方程:

$$\begin{cases} P'_0(t) = -P_0(t)\lambda_0 + P_1(t)\mu_1 \\ P'_j(t) = -P_j(t)(\lambda_j + \mu_j) + P_{j-1}(t)\lambda_{j-1} + P_{j+1}(t)\mu_{j+1}. \end{cases} \quad (6.3.5)$$

证 先证 (6.3.3).

由 C-K 方程及 (6.3.1), 有

$$\begin{aligned} \frac{P_{ij}(t+h) - P_{ij}(t)}{h} &= -P_{ij}(t) \frac{(1 - P_{jj}(h))}{h} + P_{i,j-1}(t) \frac{P_{j-1,j}(h)}{h} \\ &\quad + P_{i,j+1}(t) \frac{P_{j+1,j}(h)}{h} + \frac{1}{h} o(h) \end{aligned}$$

令 $h \rightarrow 0$ 即得 (6.3.3). 类似可证 (6.3.4). 由 (6.3.3) 两边乘以 $P_i(0)$ 再对 i 求和, 并注意到 $P_j(t) = \sum_{i \in S} P_i(0)P_{ij}(t)$, 即得 (6.3.5). \square

如 X 的极限分布存在, 即 $P_j = \lim_{t \rightarrow \infty} P_{ij}(t)$ 存在, 且与 i 无关 ($\forall i, j \in S$), 则有 $P'_j(t) \rightarrow 0 (t \rightarrow \infty)$. 因此由 (6.3.5), 令 $t \rightarrow \infty$, 两边取极限而得

$$\begin{cases} -\lambda_0 P_0 + \mu_1 P_1 = 0 \\ -(\lambda_j + \mu_j)P_j + \lambda_{j-1}P_{j-1} + \mu_{j+1}P_{j+1} = 0 \quad j \geq 1 \end{cases} \quad (6.3.6)$$

解 (6.3.6) 代数方程, 得

$$P_1 = \frac{\lambda_0}{\mu_1} P_0, \quad P_2 = \frac{\lambda_0 \lambda_1}{\mu_1 \mu_2} P_0, \quad \dots, \quad P_k = \frac{\lambda_0 \lambda_1 \cdots \lambda_{k-1}}{\mu_1 \mu_2 \cdots \mu_k} P_0, \quad \dots$$

再由 $\sum_{k \in S} P_k = 1$, 得

$$P_0 = \left(1 + \sum_{k=1}^{\infty} \frac{\lambda_0 \lambda_1 \cdots \lambda_{k-1}}{\mu_1 \mu_2 \cdots \mu_k} \right)^{-1}.$$

可知, 当

$$\sum_{k=1}^{\infty} \frac{\lambda_0 \lambda_1 \cdots \lambda_{k-1}}{\mu_1 \mu_2 \cdots \mu_k} < \infty \quad (6.3.7)$$

时, $0 < P_0 < 1$, 且 $0 < P_k < 1 (k > 1)$. 因此, (6.3.7) 式成立是 (6.3.6) 代数方程存在唯一的极限分布解的充要条件. 进一步有以下结论

定理 6.3.2 设 $X = \{X(t), t \geq 0\}$ 为生灭过程, $\lambda_i > 0, i \geq 0, \mu_i > 0, i \geq 1, (\mu_0 = 0)$, 则 X 存在唯一的平稳分布 (它等于极限分布) 的充要条件为 (6.3.7) 式成立, 即

$$\sum_{k=1}^{\infty} \frac{\lambda_0 \lambda_1 \cdots \lambda_{k-1}}{\mu_1 \mu_2 \cdots \mu_k} < \infty$$

198

且 $P_0 = \left(1 + \sum_{k=1}^{\infty} \frac{\lambda_0 \lambda_1 \cdots \lambda_{k-1}}{\mu_1 \mu_2 \cdots \mu_k} \right)^{-1}, P_k = \frac{\lambda_0 \lambda_1 \cdots \lambda_{k-1}}{\mu_1 \mu_2 \cdots \mu_k} P_0 (k \geq 1)$.

6.3 生灭过程

证 因为 (6.3.7) 式成立是 (6.3.6) 代数方程存在唯一的极限分布解的充要条件, 再由第三章定理 3.3.6: “极限分布存在是遍历的充要条件”, 所以 (6.3.7) 式成立是遍历的充要条件. 又因为生灭过程是不可约链, 且由第三章定理 3.5.6: “不可约遍历链充要条件是存在平稳分布, 且就是极限分布”, 可知 (6.3.7) 式成立是 X 存在唯一的平稳分布 (即为极限分布) 的充要条件. \square

通常在排队论中, 若存在极限分布, 且等于平稳分布, 称此时系统处于 **统计平衡**, 简称 **稳态**.

例 1 M/M/1 排队系统 即顾客到达流是参数为 λ 的 Poisson 流, 每个顾客的服务时间独立同分布, 服从参数为 μ 的指数分布且与顾客到达时间相互独立, 且只有一个服务员. 记 $X(t)$ 表示系统 t 时刻顾客数, 易知 $\{X(t), t \geq 0\}$ 为生灭过程, $\lambda_i = \lambda (i \geq 0)$, $\mu_i = \mu (i \geq 1, \mu_0 = 0)$. 显然, 当 $\rho = \frac{\lambda}{\mu} < 1$ 时, $0 < P_0 = 1 - \frac{\lambda}{\mu} < \infty$, $0 < P_k = \left(\frac{\lambda}{\mu}\right)^k \left(1 - \frac{\lambda}{\mu}\right) < \infty$, 因此得出: 对于 M/M/1 排队系统, 当 $\rho = \frac{\lambda}{\mu} < 1$ 时, 过程存在唯一平稳分布 $\{P_j, j \in S\}$, 当 $t \rightarrow +\infty$ 时, $P_j(t) \rightarrow P_j$. 以下求稳态下的几个数量指标:

1° 系统的平均队长

$$L = \lim_{t \rightarrow \infty} E[X(t)] = \sum_{k=0}^{\infty} k P_k = \sum_{k=1}^{\infty} k \left(\frac{\lambda}{\mu}\right)^k \left(1 - \frac{\lambda}{\mu}\right) = \frac{\lambda}{\mu - \lambda} = \frac{\rho}{1 - \rho}.$$

由

$$\lim_{t \rightarrow \infty} E[X^2(t)] = \sum_{k=0}^{\infty} k^2 P_k = \rho \left[\frac{2}{(1 - \rho)^2} - \frac{1}{(1 - \rho)} \right]$$

有

$$\lim_{t \rightarrow \infty} D[X(t)] = \frac{\rho}{(1 - \rho)^2}.$$

2° 平均等待的顾客数

$$L_g = \sum_{k=1}^{\infty} (k - 1) P_k = \frac{\lambda^2}{\mu(\mu - \lambda)} = \frac{\rho^2}{(1 - \rho)}.$$

3° 等待时间分布与平均等待时间

以 T_g 表示稳态时 (如考虑初始分布等于平稳分布的系统, 此时是一平稳过程) 顾客排队等待的时间, 记 $G(x) = P(T_g \leq x)$, 当 $x = 0$ 时

$$G(0) = P(T_g = 0) = P_0 = \left(1 - \frac{\lambda}{\mu}\right).$$

$x > 0$ 时, 由全概公式

$$\begin{aligned} G(x) &= \sum_{n=0}^{\infty} P(X(s) = n) P(T_g \leq x | X(s) = n) \\ &= P(T_g \leq x, X(s) = 0) + \sum_{n=1}^{\infty} P_n P(T_g \leq x | X(s) = n). \end{aligned}$$

在 $X(s) = n$ 条件下, T_g 应等于 $(n-1)$ 个顾客服务时间之和再加上正在服务的顾客的剩余服务时间, 再由指数分布的无记忆性, 知 $P(T_g \leq x | X(s) = n)$ 应等于参数为 μ 的指数分布的 n 重卷积, 即

$$P(T_g \leq x | X(s) = n) = \int_0^x \frac{\mu(\mu u)^{n-1}}{(n-1)!} e^{-\mu u} du,$$

故

$$\begin{aligned} G(x) &= \left(1 - \frac{\lambda}{\mu}\right) + \left(1 - \frac{\lambda}{\mu}\right) \lambda \int_0^x \sum_{n=1}^{\infty} \frac{(\lambda \mu)^{n-1}}{(n-1)!} e^{-\mu u} du \\ &= \left(1 - \frac{\lambda}{\mu}\right) + \frac{\lambda}{\mu} [1 - e^{-(\mu-\lambda)x}] \\ &= 1 - \frac{\lambda}{\mu} e^{-(\mu-\lambda)x}. \end{aligned}$$

平均等待时间 $W_g = ET_g = \frac{\lambda}{\mu(\mu-\lambda)}$.

4° 费用最优的参数

考虑最优服务率 μ 的问题, 设每一顾客在系统一小时损失 C_1 元, 服务机构每小时费用正比于 μ , 比例系数为 C_2 , 记 $R(\mu)$ 为每小时费用, 则系统平均每小时费用损失为 $ER(\mu) = \frac{\lambda}{\mu-\lambda} C_1 + C_2 \mu$. 如何选取最优的 μ^* , 使 $ER(\mu^*) = \min ER(\mu)$, 显然由 $\frac{dER(\mu)}{d\mu} = 0$, 可得

$$\mu^* = \lambda + \sqrt{\frac{C_1 \lambda}{C_2}}.$$

例 2 一台大型计算机系统, 有 m 个终端, 假定可能的用户有无限多. 在 $(t, t+h)$ 内又有一用户要求使用终端的概率为 $\lambda h + o(h)$ ($\lambda > 0, h$ 充分小), 并与正在使用的用户无关. 此时若有空闲终端, 则它占用一终端; 否则, 因终端占满, 请求使用的用户被取消. 又假定每一个在 t 时刻正在占用一终端, 在 $(t, t+h)$ 内使用完毕而空出的概率为 $\mu h + o(h)$. 各用户正在占用与结束之间相互独立. 设 $X(t)$ 表 t 时刻正在占用的终端数, 易验证 $\{X(t), t \geq 0\}$ 为 MC, 且是有限状态生灭过程, $S = \{0, 1, 2, \dots, m\}$. 依题意:

$$P_{i,i+1}(h) = \lambda h + o(h), \quad 0 \leq i \leq m-1.$$

$$P_{i,i-1}(h) = i\mu h + o(h), \quad 1 \leq i \leq m.$$

$$P_{ii}(h) = 1 - (\lambda + i\mu)h + o(h), \quad 0 \leq i \leq m-1.$$

$$P_{ij}(h) = o(h), \quad |j-i| \geq 2.$$

$$P_{mm}(h) = 1 - m\mu h + o(h). \quad 200$$

则相应的极限分布 $\{P_j, 0 \leq j \leq m\}$ 满足 (6.3.6) 方程 ($0 \leq j \leq m$). 解之得: $P_k =$

6.3 生灭过程

$\frac{1}{k!} \left(\frac{\lambda}{\mu}\right)^k P_0$, 再由 $\sum_{j=0}^m P_j = 1$ 知

$$P_0 = \left(1 + \sum_{k=1}^m \frac{1}{k!} \left(\frac{\lambda}{\mu}\right)^k\right)^{-1},$$

$$P_k = \frac{1}{k!} \left(\frac{\lambda}{\mu}\right)^k \left[\sum_{l=0}^m \frac{1}{l!} \left(\frac{\lambda}{\mu}\right)^l\right]^{-1}, \quad 0 \leq k \leq m.$$

考虑几个特殊的生灭过程

(a) 有迁入的线性增长模型 生灭过程 $X = \{X(t), t \geq 0\}$, 若 $\lambda_n = n\lambda + a$, $\mu_n = n\mu$, $\lambda > 0$, $\mu > 0$, $a > 0$, 称 X 为有迁入线性增长模型. 它用于描述生物再生和人口增长过程. 假定群体中的每个个体以指数率 λ 出生, 同时, 群体由于从外界迁入的影响又以系数 a 增加, 而群体中每个个体以指数率 μ 死亡. 这时 (6.3.3) 方程化为:

$$\begin{cases} P'_{i0}(t) = -aP_{i0}(t) + \mu P_{i1}(t) \\ P'_{ij}(t) = [\lambda(j-1) + a]P_{i,j-1}(t) - [(\lambda + \mu)j + a]P_{ij}(t) + \mu(j+1)P_{i,j+1}(t), \quad j \geq 1 \end{cases} \quad (6.3.8)$$

记 $M_i(t) = E[X(t)|X(0) = i] = \sum_{j=1}^{\infty} j P_{ij}(t)$, 则由 (6.3.8) 两边乘以 j , 再对 j 求和, 可知 $(M_i(t), t \geq 0)$ 满足下列微分方程

$$\begin{cases} M'_i(t) = a + (\lambda - \mu)M_i(t) \\ M_i(0) = i. \end{cases}$$

解之得到

$$M_i(t) = \begin{cases} at + i, & \text{如 } \lambda = \mu \\ \frac{a}{\lambda - \mu}(e^{(\lambda - \mu)t} - 1) + ie^{(\lambda - \mu)t}, & \text{如 } \lambda \neq \mu. \end{cases} \quad (6.3.9)$$

且

$$\lim_{t \rightarrow \infty} M_i(t) = \begin{cases} \infty, & \text{如 } \lambda \geq \mu \\ \frac{-a}{\lambda - \mu}, & \text{如 } \lambda < \mu. \end{cases}$$

这在直观上的意义是很明显的.

(b) 纯生过程 (yule 过程)

Poisson 过程是一个最简单的纯生过程, 它是当 $\mu_n = 0$, $\lambda_n = \lambda$ 的生灭过程. Poisson 过程的一个自然推广是在给定时刻一事件发生的可能性依赖于已发生的事件数, 即对于充分小的 $h \geq 0$, 若 $P_{i,i+1}(h) = \lambda_i h + o(h)$, $P_{ii}(h) = 1 - \lambda_i h + o(h)$, 其它 $P_{ij}(h) = o(h)$, $j > i+1$, $P_{ij}(h) = 0$, $j < i$, 这便是纯生过程. 纯生过程中一个特殊情形是: 当 $\lambda_n = n\beta$ 时, 称为 yule 过程. yule 过程在物理, 生物中常会看到它的踪迹. 假定某群体的每一位个体在 h 时间长度内生出新的概率为 $\beta h + o(h)$, 且个体之间产生下一代的个体数也相互独立, 那

么

$$\begin{aligned}
 P_{i,i+1}(h) &= P(X(t+h) = i+1 | X(t) = i) \\
 &= P(X(t+h) - X(t) = 1 | X(t) = i) \\
 &= C_n^1(\beta h + o(h)) [1 - \beta h + o(h)]^{n-1} \\
 &= n\beta h + o(h)
 \end{aligned}$$

当 $j > i+1$ 时, $P_{ij}(h) = o(h)$; $j < i$ 时, $P_{ij}(h) = 0$, $P_{ii}(h) = (1 - \beta h - o(h))^n = 1 - n\beta h + o(h)$. 以 $\lambda_n = n\beta$, $\mu_n = 0$ 代入 (6.3.5) 得

$$P'_n(t) = -n\beta P_n(t) + (n-1)\beta P_{n-1}(t), \quad n \geq 1 \quad (6.3.10)$$

分二种情况讨论:

1° 设 $X(0) = 1$, 即 $P_1(0) = 1$, $P_n(0) = 0 (n \geq 2)$ 为初始条件, 由 $n = 1$, $P'_1(t) = -\beta P_1(t)$, $P_1(0) = 1$, 得 $P_1(t) = e^{-\beta t}$, 再由 (6.3.10) 递推归纳得:

$$P_n(t) = \exp(-\beta t) [1 - \exp(-\beta t)]^{n-1}, \quad n \geq 1.$$

记 $f_1(\rho, t) = \sum_{n=1}^{\infty} P_n(t) \rho^n$, 那么

$$f_1(\rho, t) = \frac{\rho e^{-\beta t}}{1 - (1 - e^{-\beta t})\rho}.$$

2° 设 $X(0) = k$, 即 $P_k(0) = 1$, $P_n(0) = 0, n \neq k$ 的情形, 由于每个个体生下一代相互独立, 因此我们可以设想: 这个 $X(0) = k$ 的 yule 过程可以看作是由 $X_i(0) = 1$ 的 k 个 yule 过程 $X_i(t) (1 \leq i \leq k)$ 的和构成, 即 $X(t) = \sum_{i=1}^k X_i(t)$. 并令

$$P_{kn}(t) = P(X(t) = n | X(0) = k)$$

$$f_k(\rho, t) = \sum_{n=k}^{\infty} P_{kn}(t) \rho^n$$

则有

$$\begin{aligned}
 f_k(\rho, t) &= [f_1(\rho, t)]^k \\
 &= \left[\frac{\rho e^{-\beta t}}{1 - (1 - e^{-\beta t})\rho} \right]^k \\
 &= (\rho e^{-\beta t})^k \sum_{m=0}^{\infty} C_{m+k-1}^m (1 - e^{-\beta t})^m \rho^m \\
 &= \sum_{n=k}^{\infty} C_{n-1}^{n-k} (e^{-\beta t})^k (1 - e^{-\beta t})^{n-k} \rho^n
 \end{aligned}$$

6.4 强马氏性与嵌入马氏链

与 $f_k(\rho, t)$ 的定义比较, 得

$$\begin{cases} P_{kn}(t) = C_{n-1}^{n-k} e^{-k\beta t} (1 - e^{-\beta t})^{n-k} & n \geq k \\ P_{kn}(t) = 0 & n < k \end{cases}$$

这说明, 对 yule 过程, 由初始分布及 Q 矩阵能够唯一确定 $P(t)$.

§ 6.4 强马氏性与嵌入马氏链

在马氏链中, 它的基本性质是它具有“马氏性”, 即已知“现在”, “将来”与“过去”历史无关. 这里所指的“现在”时刻 t 是一个 T 中的数. 自然地要问: 如果“现在”改为随机“停时”, 其“马氏性”是否还保持? 例如, 已知过程在第一次跳跃时刻 τ_1 (现在是时刻是 τ_1) 的状态, 那么过程在第一次跳跃后 (将来) 与过程在 τ_1 之前是否条件独立? 这就是所谓“强马氏性”问题. 强马氏性概念是一个非常有用的概念, 但它的严格定义需要测度论的知识. 本节力图用直观的, 初等概率论的语言对“强马氏性”与有关的重要结果作简要的介绍, 以便读者应用.

记 $F_t = \sigma(X(u), 0 \leq u \leq t)$ 是由 $\{X(u), 0 \leq u \leq t\}$ 生成的事件的 σ 域, 即由过程 X 在 $[0, t]$ 内可能提供的全部信息 (参见第四章 § 4.3). 一个非负随机变量 τ , 若对于 $\forall t \geq 0$ 有 $(\tau \leq t) \in F_t$, 即事件 $\{\tau \leq t\}$ 发生与否, 完全由过程 X 在 t 时刻之前 (包括 t 时刻) 的状态 $\{X(u), 0 \leq u \leq t\}$ 决定, 则称 τ 关于 $X = \{X(t), t \geq 0\}$ 是停时 (或马氏时间). 显然, 任意常数 $t \geq 0$ 是停时. 若 τ, θ 是停时, 则 $\tau + \theta, \tau \wedge \theta, \tau \vee \theta$ 亦是停时.

定义 设马氏过程 $X = \{X(t), t \geq 0\}$, 状态空间 $S = \{0, 1, 2, \dots\}$, 设 ρ_n 关于 X 是停时 ($n \geq 1$), $0 \leq \rho_1 \leq \rho_2 \leq \dots \leq \rho_n$ 及 $t \geq 0$, 若对 $\forall j, i_k \in S (0 \leq k \leq n)$ 有

$$\begin{aligned} P\{X(\rho_n + t) = j | X(0) = i_0, X(\rho_k) = i_k, (1 \leq k \leq n)\} \\ = P\{X(\rho_n + t) = j | X(\rho_n) = i_n\}, \end{aligned}$$

则称 $\{X(t), t \geq 0\}$ 关于 $\{\rho_k, 0 \leq k \leq n\} (n \geq 1)$ 具有强马氏性. □

以下我们总假定时齐马氏链 $X = \{X(t), t \geq 0\}$ 轨道右连续, $Q = (q_{ij})$ 为保守 Q 矩阵, 且 $0 < q_i < \infty, i \in S$, 并着重讨论 X 关于跳跃时刻的强马氏性问题. 令 $\tau_0 = 0$,

$$\tau_n = \inf\{t : t > \tau_{n-1}, X(t) \neq X(\tau_{n-1})\} (n \geq 1)$$

$$\theta_n = \tau_n - \tau_{n-1} (n \geq 1)$$

τ_n 表示 X 的第 n 次跳跃时刻, θ_n 表示第 n 次与第 $n-1$ 次跳跃的时间间隔. 令 $Y^{(n)}(t) = X(\tau_n + t)$, $Y^{(n)} = \{X(\tau_n + t), t \geq 0\} (n \geq 1)$, $\tau_0^{(1)} = 0$, $\tau_n^{(1)} = \inf\{t : t > \tau_{n-1}^{(1)}, Y^{(1)}(t) \neq Y^{(1)}(\tau_{n-1}^{(1)})\}$.

定理 6.4.1 $\forall s, t \geq 0, j \neq i$, 有

$$\begin{aligned} & P\{\tau_1 \leq s, X(\tau_1 + v) = j, 0 \leq v \leq t | X(0) = i, X(\tau_1) = j\} \\ &= [1 - \exp(-q_i s)] \exp(-q_j t) \end{aligned} \quad (6.4.1)$$

证 由定理 6.1.4 的推论知

$$\begin{aligned} & P(\tau_1 \leq u | X(0) = i, X(\tau_1) = j) \\ &= P(\tau_1 \leq u | X(0) = i) \\ &= 1 - \exp(-q_i u). \end{aligned}$$

故

$$\begin{aligned} & P[\tau_1 \leq s, X(\tau_1 + v) = j, 0 \leq v \leq t | X(0) = i, X(\tau_1) = j] \\ &= \int_0^s P\{\tau_1 \leq s, X(\tau_1 + v) = j, 0 \leq v \leq t | X(0) = i, \tau_1 = u, X(u) = j\} \\ & \quad dP\{\tau_1 \leq u | X(0) = i, X(\tau_1) = j\} \\ &= \int_0^s P\{X(u + v) = j, 0 \leq v \leq t | X(s) = i, 0 \leq s < u, X(u) = j\} q_i \exp(-q_i u) du \\ &= \int_0^s P\{X(u + v) = j, 0 \leq v \leq t | \bigcap_{n=1}^{\infty} \left(X\left(\frac{k}{2^n}u\right) = i, 0 \leq k \leq 2^n - 1 \right), X(u) = j\} \\ & \quad q_i \exp(-q_i u) du \quad (\text{轨道右连续}) \\ &= \int_0^s P[(X(u + v) = j, 0 \leq v \leq t | X(u) = j] q_i \exp(-q_i u) du \quad (\text{马氏性}) \\ &= \int_0^s P[X(v) = j, 0 \leq v \leq t | X(0) = j] q_i \exp(-q_i u) du \quad (\text{时齐性}) \\ &= P[X(v) = j, 0 \leq v \leq t | X(0) = j] [1 - \exp(-q_i s)] \\ &= [1 - \exp(-q_i s)] \exp(-q_j t) \quad (\text{由 (6.1.5) 式}). \quad \square \end{aligned}$$

推论 1 $\forall s, t \geq 0, j \neq i$

$$(1) P(\theta_1 \leq s, \theta_2 \leq t | X(0) = i, X(\tau_1) = j) = [1 - \exp(-q_i s)][1 - \exp(-q_j t)].$$

证 因为

$$\begin{aligned} & P(\tau_1 \leq s, \tau_2 - \tau_1 > t | X(0) = i, X(\tau_1) = j) \\ &= P(\tau_1 \leq s, X(\tau_1 + v) = j, 0 \leq v \leq t | X(0) = i, X(\tau_1) = j) \\ &= (1 - e^{-q_i s}) e^{-q_j t} \quad (\text{定理 6.4.1}) \end{aligned}$$

6.4 强马氏性与嵌入马氏链

所以

$$\begin{aligned}
 & P(\theta_1 \leq s, \theta_2 \leq t | X(0) = i, X(\tau_1) = j) \\
 &= P(\tau_1 \leq s, \tau_2 - \tau_1 \leq t | X(0) = i, X(\tau_1) = j) \\
 &= P(\tau_1 \leq s | X(0) = i, X(\tau_1) = j) - P(\tau_1 \leq s, \tau_2 - \tau_1 > t | X(0) = i, X(\tau_1) = j) \\
 &= (1 - e^{-q_i s}) - (1 - e^{-q_i s})e^{-q_j t} \\
 &= (1 - e^{-q_i s})(1 - e^{-q_j t}) \quad \square
 \end{aligned}$$

(2) 给定 $X(0)$, $X(\tau_1)$, θ_1 与 θ_2 条件独立.

证 因为

$$\begin{aligned}
 & P(\theta_1 \leq s, \theta_2 \leq t | X(0) = i, X(\tau_1) = j) \\
 &= [1 - \exp(-q_i s)][1 - \exp(-q_j t)] \quad (\text{上一结论})
 \end{aligned}$$

且, 令 $t \rightarrow \infty$, 可得

$$P(\theta_1 \leq s | X(0) = i, X(\tau_1) = j) = 1 - \exp(-q_i s).$$

令 $s \rightarrow \infty$, 可得

$$P(\theta_2 \leq t | X(0) = i, X(\tau_1) = j) = 1 - \exp(-q_j t).$$

所以

$$\begin{aligned}
 & P(\theta_1 \leq s, \theta_2 \leq t | X(0) = i, X(\tau_1) = j) \\
 &= P(\theta_1 \leq s | X(0) = i, X(\tau_1) = j) \cdot P(\theta_2 \leq t | X(0) = i, X(\tau_1) = j).
 \end{aligned}$$

独立性得证. \square

(3) $X = \{X(t), t \geq 0\}$ 关于 τ_1 具有强马氏性.

证 因为

$$\begin{aligned}
 & P(X(\tau_1 + t) = k | X(0) = i, X(\tau_1) = j) \\
 &= \int_0^\infty P(X(\tau_1 + t) = k | X(0) = i, \tau_1 = u, X(u) = j) q_i \exp(-q_i u) du \quad (\text{全概率公式}) \\
 &= \int_0^\infty P(X(u + t) = k | X(s) = i, 0 \leq s < u, X(u) = j) q_i \exp(-q_i u) du \\
 &= \int_0^\infty P(X(t) = k | X(0) = j) q_i \exp(-q_i u) du \quad (\text{马氏性, 时齐性}) \\
 &= P_{jk}(t).
 \end{aligned}$$

所以

$$\begin{aligned}
 & P(X(\tau_1 + t) = k | X(\tau_1) = j) \\
 &= \sum_i P(X(\tau_1 + t) = k | X(0) = i, X(\tau_1) = j) \cdot P(X(0) = i | X(\tau_1) = j) \quad (\text{全概率公式}) \\
 &= \sum_i P_{jk}(t) \cdot P(X(0) = i | X(\tau_1) = j) \\
 &= P_{jk}(t) \cdot 1 \\
 &= P_{jk}(t).
 \end{aligned}$$

故

$$P(X(\tau_1 + t) = k | X(0) = i, X(\tau_1) = j) = P(X(\tau_1 + t) = k | X(\tau_1) = j).$$

即 $X = \{X(t), t \geq 0\}$ 关于 τ_1 有强马氏性. \square

定理 6.4.2 $Y^{(1)} = \{X(\tau_1 + t), t \geq 0\}$ 是时齐 MC, 且与 $X = \{X(t), t \geq 0\}$ 有相同的 $P(t) = (P_{ij}(t))$ 和 Q 矩阵 $Q = (q_{ij})$, 同时 $Y^{(1)}$ 与 X 的初始分布无关.

证 由推论 1(3) 的证明可知 $\forall i, j, k \in S, j \neq i, t \geq 0$, 有

$$P\{X(\tau_1 + t) = k | X(0) = i, X(\tau_1) = j\} = P_{jk}(t)$$

且在给定 $X(\tau_1)$ 下, $X(\tau_1 + t)$ 与 $X(0)$ 条件独立.

下面证: $\forall 0 < u_1 < u_2 < \cdots < u_n, i_k \in S, 0 \leq k \leq n, l \neq i_0, t \geq 0$, 有

$$P\{\tau_1 \leq t | X(0) = l, X(\tau_1) = i_0, X(\tau_1 + u_1) = i_1, \cdots, X(\tau_1 + u_n) = i_n\} = (1 - \exp(-q_l t)) \quad (6.4.2)$$

即在给定 $X(0)$ 下, τ_1 与 $X(\tau_1), X(\tau_1 + u_1), \cdots, X(\tau_1 + u_n)$ 条件独立. 注意到由于

$$\begin{aligned}
 & P\{X(\tau_1) = i_0, X(\tau_1 + u_1) = i_1, \cdots, X(\tau_1 + u_n) = i_n | X(0) = k\} \\
 &= \int_0^\infty P\{X(u) = i_0, X(u + u_1) = i_1, \cdots, X(u + u_n) = i_n | X(0) = l, \tau_1 = u\} \\
 &\quad q_l \exp(-q_l u) \, du \\
 &= \int_0^\infty P\{X(u) = i_0 | X(0) = l, \tau_1 = u\} P\{X(u + u_1) = i_1 | X(0) = l, \tau_1 = u, X(u) = i_0\} \\
 &\quad \cdots P\{X(u + u_n) = i_n | X(0) = l, X(u) = i_0, \tau_1 = u, X(u + u_1) = i_1, \\
 &\quad \cdots, X(u + u_{n-1}) = i_{n-1}\} q_l \exp(-q_l u) \, du \\
 &= P_{i_0, i_1}(u_1) P_{i_1, i_2}(u_2) \cdots P_{i_{n-1}, i_n}(u_n) \int_0^\infty P\{X(u) = i_0 | X(0) = l, \tau_1 = u\} q_l \exp(-q_l u) \, du \\
 &= P_{i_0, i_1}(u_1) P_{i_1, i_2}(u_2) \cdots P_{i_{n-1}, i_n}(u_n) P\{X(\tau_1) = i_0 | X(0) = l\} \\
 &= P_{i_0, i_1}(u_1) P_{i_1, i_2}(u_2) \cdots P_{i_{n-1}, i_n}(u_n) q_{li_0} / q_l
 \end{aligned}$$

而

$$\begin{aligned}
& P\{\tau_1 \leq t, X(\tau_1) = i_0, X(\tau_1 + u_1) = i_1, \dots, X(\tau_1 + u_n) = i_n | X(0) = l\} \\
&= \int_0^t P\{X(u) = i_0, X(u + u_1) = i_1, \dots, X(u + u_n) = i_n | X(0) = l, \tau_1 = u\} \\
&\quad q_l \exp(-q_l u) du \\
&= \int_0^t P\{X(u) = i_0 | X(0) = l, \tau_1 = u\} P\{X(u + u_1) = i_1 | X(0) = l, \tau_1 = u, X(u) = i_0\} \\
&\quad \cdots P\{X(u + u_n) = i_n | X(0) = l, X(u) = i_0, \tau_1 = u, X(u + u_1) = i_1, \\
&\quad \cdots, X(u + u_{n-1}) = i_{n-1}\} q_l \exp(-q_l u) du \\
&= P_{i_0, i_1}(u_1) P_{i_1, i_2}(u_2) \cdots P_{i_{n-1}, i_n}(u_n) \int_0^t -P\{X(u) = i_0 | X(0) = l, \tau_1 = u\} \\
&\quad q_l \exp(-q_l u) du \\
&= P_{i_0, i_1}(u_1) P_{i_1, i_2}(u_2) \cdots P_{i_{n-1}, i_n}(u_n) P\{\tau_1 \leq t, X(\tau_1) = i_0 | X(0) = l\} \\
&= P_{i_0, i_1}(u_1) P_{i_1, i_2}(u_2) \cdots P_{i_{n-1}, i_n}(u_n) (1 - \exp(-q_l t)) q_l i_0 / q_l
\end{aligned}$$

故

$$\begin{aligned}
& P\{\tau_1 \leq t | X(0) = l, X(\tau_1) = i_0, X(\tau_1 + u_1) = i_1, \dots, X(\tau_1 + u_n) = i_n\} \\
&= \frac{P\{\tau_1 \leq t, X(\tau_1) = i_0, X(\tau_1 + u_1) = i_1, \dots, X(\tau_1 + u_n) = i_n | X(0) = l\}}{P\{X(\tau_1) = i_0, X(\tau_1 + u_1) = i_1, \dots, X(\tau_1 + u_n) = i_n | X(0) = l\}} \\
&= 1 - \exp(-q_l t)
\end{aligned}$$

从而 (6.4.2) 式得证.

再证 $Y^{(1)} = \{X(\tau_1 + t), t \geq 0\}$ 为时齐 MC, 具有 $P(t) = (P_{ij}(t))$. 即对 $\forall 0 < u_1 < u_2 < \cdots < u_{n-1} < u, t \geq 0, l \neq i_0, i_k \in S, 0 \leq k \leq n-1, i, j \in S$, 证明

$$P\{Y^{(1)}(u + t) = j | X(0) = l, Y^{(1)}(0) = i_0, Y^{(1)}(u_1) = i_0, \dots, Y^{(1)}(u_{n-1}) = i_{n-1},$$

$$Y^{(1)}(u) = i\} = P_{ij}(t).$$

注意到由 (6.4.2) 式, 可得: 上式左边

$$\begin{aligned}
&= P\{X(\tau_1 + u + t) = j | X(0) = l, X(\tau_1) = i_0, X(\tau_1 + u_1) = i_1, \dots, X(\tau_1 + u) = i\} \\
&= \int_0^\infty P\{X(v + u + t) = j | X(0) = l, X(v) = i_0, X(v + u_1) = i_1, \dots, X(v + u) = i, \\
&\quad \tau_1 = v\} q_l \exp(-q_l v) dv \\
&= \int_0^\infty P\{X(v + u + t) = j | X(s) = l, 0 \leq s < v, X(v) = i_0, \dots, X(v + u) = i\} \\
&\quad q_l \exp(-q_l v) dv \\
&= \int_0^\infty P\{X(v + u + t) = j | X(v + u) = i\} q_l \exp(-q_l v) dv \\
&= \int_0^\infty P\{X(t) = j | X(0) = i\} q_l \exp(-q_l v) dv \\
&= P_{ij}(t).
\end{aligned}$$

知 $Y^{(1)}$ 与 X 具有相同的转移概率矩阵 $P(t) = (P_{ij}(t))$ 和 Q 矩阵 $Q = (q_{ij})$, 且 $Y^{(1)}$ 与 X 的初始分布无关. \square

推论 $Y^{(n)} = \{X(\tau_n + t), t \geq 0\}$ 是时齐 MC 且与 $X = \{X(t), t \geq 0\}$ 具有相同的 $P(t) = (P_{ij}(t))$ 与 Q 矩阵 $Q = (q_{ij})$.

证 用数学归纳法. $n = 1$ 时, 成立.

设 n 时成立, 即

$$\begin{aligned}
&P(Y^{(n)}(u + t) = j | Y^{(n)}(0) = i_0, Y^{(n)}(u_1) = i_0, \dots, Y^{(n)}(u_{n-1}) = i_{n-1}, Y^{(n)}(u) = i) \\
&= P_{ij}(t).
\end{aligned}$$

对 $n + 1$ 时:

$$\begin{aligned}
&P(Y^{(n+1)}(u + t) = j | Y^{(n+1)}(0) = i_0, \dots, Y^{(n+1)}(u) = i) \\
&= P(X(\tau_{n+1} + u + t) = j | X(\tau_{n+1}) = i_0, \dots, X(\tau_{n+1} + u) = i) \\
&= P(Y^{(1)}(\tau_n^{(1)} + u + t) = j | Y^{(1)}(\tau_n^{(1)}) = i_0, \dots, Y^{(1)}(\tau_n^{(1)} + u) = i) \\
&= P(X(\tau_n^{(1)} + u + t) = j | X(\tau_n^{(1)}) = i_0, \dots, X(\tau_n^{(1)} + u) = i) \quad (n = 1 \text{ 时成立}) \\
&= P(Y^{(n)}(u + t) = j | Y^{(n)}(0) = i_0, \dots, Y^{(n)}(u_{n-1}) = i_{n-1}, Y^{(n)}(u) = i) \\
&= P_{ij}(t). \quad (\text{归纳假设}) \square
\end{aligned}$$

可以证明 $\tau_n (n \geq 1)$ 关于 X 是停时 (证略).

定理 6.4.3 马氏链 $X = \{X(t), t \geq 0\}$ 关于跳跃时刻 $\{\tau_k, 0 \leq k \leq n\} (n \geq 1)$ 具有强

6.4 强马氏性与嵌入马氏链

马氏性, 即 $\forall t \geq 0, i_k \in S, i_{k-1} \neq i_k, 1 \leq k \leq n-1, i_{n-1} \neq i, j \in S$, 则

$$\begin{aligned} & P\{X(\tau_n + t) = j | X(0) = i_0, X(\tau_1) = i_1, \dots, X(\tau_{n-1}) = i_{n-1}, X(\tau_n) = i\} \\ &= P\{X(\tau_n + t) = j | X(\tau_n) = i\} \\ &= P_{ij}(t) \end{aligned}$$

证 用数学归纳法. 当 $n = 1$ 时, 由定理 6.4.1 知结论成立.

现设 (6.4.3) 对 n 成立, 往下证对 $n+1$ 的情形. 由定理 6.4.2 知 $Y^{(1)}$ 在 $X(\tau_1)$ 下与 $X(0)$ 无关, 于是

$$\begin{aligned} & P\{X(\tau_{n+1} + t) = j | X(0) = i_0, X(\tau_1) = i_1, \dots, X(\tau_{n+1}) = i\} \\ &= P\{Y^{(1)}(\tau_n^{(1)} + t) = j | Y^{(1)}(0) = i_0, Y^{(1)}(\tau_1^{(1)}) = i_1, \dots, Y^{(1)}(\tau_n^{(1)}) = i\} \\ &= P\{Y^{(1)}(\tau_n^{(1)} + t) = j | Y^{(1)}(\tau_n^{(1)}) = i\} \quad (\text{由归纳假设}) \\ &= P_{ij}(t) \quad (\text{定理 6.4.2}) \end{aligned}$$

从而结论对任意 $n \geq 1$ 均成立. \square

由以上定理, 不难有以下

推论

(1) $\forall i_k \in S, i_k \neq i_{k+1}, 0 \leq k \leq n-1, i \neq i_{n-1}, t \geq 0$

$$\begin{aligned} & P\{\theta_{n+1} \leq t | X(0) = i_0, X(\tau_1) = i_1, \dots, X(\tau_{n-1}) = i_{n-1}, X(\tau_n) = i\} \\ &= 1 - \exp(-q_i t) \end{aligned} \tag{6.4.4}$$

(2) 关于 $X(0), X(\tau_1), \dots, X(\tau_n), \theta_1, \theta_2, \dots, \theta_n, \theta_{n+1}$ 条件独立.

(3)

$$P\{X(\tau_{n+1}) = j | X(0) = i_0, \dots, X(\tau_{n-1}) = i_{n-1}, X(\tau_n) = i\} = \begin{cases} \frac{q_{ij}}{q_i} & j \neq i \\ 0 & j = i \end{cases}$$

仅证 (3).

证 左边

$$\begin{aligned} &= P(X(\tau_n + \theta_{n+1}) = j | X(0) = i_0, \dots, X(\tau_n) = i) \\ &= \int_0^\infty P(X(\tau_n + t) = j | X(0) = i_0, \dots, X(\tau_n) = i, \theta_{n+1} = t) \\ &\quad dP(\theta_{n+1} \leq t | X(0) = i_0, \dots, X(\tau_n) = i) \\ &= \int_0^\infty P(X(\tau_n + u) = i, 0 \leq u < t, X(\tau_n + t) = j | X(0) = i_0, \dots, X(\tau_n) = i, \theta_{n+1} = t) \\ &\quad dP(\theta_{n+1} \leq t | X(\tau_n) = i) \end{aligned}$$

$$= \int_0^\infty P(X(u) = i, 0 \leq u < t, X(t) = j | X(0) = i, \theta_1 = t) dP(\theta_1 \leq t | X(0) = i)$$

$$\begin{aligned}
 &= \int_0^\infty P(X(\tau_1) = j | X(0) = i) \quad (\text{全概率公式}) \\
 &= \frac{q_{ij}}{q_i}. \quad \square
 \end{aligned}$$

若令 $\tilde{X} = X(\tau_n)$, 则 $\{\tilde{X}_n, n \geq 0\}$ 有以下

定理 6.4.4 $\tilde{X} = \{\tilde{X}_n, n \geq 0\}$ 是离散参数 MC, 其一步转移概率 \tilde{P}_{ij} 为

$$\tilde{P}_{ij} = \begin{cases} \frac{q_{ij}}{q_i} & j \neq i \\ 0 & j = i. \end{cases}$$

$$\tilde{P} = (\delta_{ij} + q_{ij}q_i^{-1})$$


证 由定理 6.4.3 推论即得. \square

称 $\tilde{X} = \{\tilde{X}_n, n \geq 0\}$ 为 **嵌入马氏链**.

以上说明: 对于连续参数马氏链 $X = \{X(t), t \geq 0\}$, 如果我们只考虑跳跃时刻 $\{\tau_n, n \geq 0\}$ 的状态 $\tilde{X}_n = X(\tau_n)$, 则 $\tilde{X} = \{\tilde{X}_n, n \geq 0\}$ 仍是 MC, 其转移矩阵为 $\tilde{P} = (\delta_{ij} + q_{ij}q_i^{-1})$.

§ 6.5 连续参数马氏链的随机模拟

从上节讨论知道, 对于连续参数马氏链 $X = \{X(t), t \geq 0\}$, 当给定 $X(\tau_n) = i_n (n \geq 0)$ 时, 停留在 i_n 状态的时间 $\{\theta_n, n \geq 1\}$ 条件独立, 且 θ_n 服从参数为 q_{i_n} 的指数分布. 而状态转移概率 $P\{X(\tau_{n+1}) = i_{n+1} | X(\tau_n) = i_n\} = q_{i_n, i_{n+1}}/q_{i_n}$, 故 X 的轨道可形象表示如图 6.5.1.



因此对于初始分布为 $\{P_j(0), j \in S\}$, Q 矩阵 $Q = (q_{ij})$ 为保守的马氏链 $X = \{X(t), t \geq 0\}$ 轨道的模拟可分为以下三部分:

- 1° 初始分布 $P_i(0)$ 的模拟;
- 2° 停留时间 $\{\theta_n, n \geq 1\}$ 的模拟;
- 3° 状态转移 $\tilde{P}_{ij} = P(X(\tau_{n+1}) = j | X(\tau_n) = i) = \delta_{ij} + q_{ij}q_i^{-1}$ 的模拟.

具体模拟步骤如下:

6.5 连续参数 MC 的随机模拟

1° 取两串相互独立的同为 $(0, 1)$ 上的均匀分布随机变量序列 $\{U_n, n \geq 0\}$ 及 $\{V_n, n \geq 1\}$;

2° 若 U_0 满足

$$\sum_{k=0}^{i_0-1} P_k(0) \leq U_0 < \sum_{k=0}^{i_0} P_k(0)$$

则取 $X(0) = i_0$ 作为初始状态;

3° 取出 U_1 , 令 $\theta_1 = -q_{i_0}^{-1} \ln U_1$ 作为 $X(t)$ 停留在 $X(0) = i_0$ 的时间;

4° 取出 V_1 , 若 $i_1 \in S$ 使 V_1 满足

$$\sum_{k=0}^{i_1-1} \frac{q_{i_0 k}}{q_{i_0}} \leq V_1 < \sum_{k=0}^{i_1} \frac{q_{i_0 k}}{q_{i_0}},$$

则取 $X(\tau_1) = X(\theta_1) = i_1$;

5° 取出 U_2 , 令 $\theta_2 = -q_{i_1}^{-1} \ln U_2$ 作为 $X(t)$ 停留在 $X(\tau_1) = i_1$ 状态的停留时间, 再取 $\tau_2 = \theta_1 + \theta_2$, 作为第二次跳跃时刻;

6° 取出 V_2 , 若 $i_2 \in S$ 使 V_2 满足

$$\sum_{k=0}^{i_2-1} \frac{q_{i_1 k}}{q_{i_1}} \leq V_2 < \sum_{k=0}^{i_2} \frac{q_{i_1 k}}{q_{i_1}},$$

则取 $X(\tau_2) = i_2$;

.....

继续以上步骤

7° 取出 U_n , 令 $\theta_n = -q_{i_{n-1}}^{-1} \ln U_n$ 作为 $X(t)$ 停留在 $X(\tau_{n-1}) = i_{n-1}$ 状态的停留时间, 再取 $\tau_n = \sum_{k=1}^n \theta_k$;

8° 取出 V_n , 若 $i_n \in S$ 使 V_n 满足

$$\sum_{k=0}^{i_n-1} \frac{q_{i_{n-1}, k}}{q_{i_{n-1}}} \leq V_n < \sum_{k=0}^{i_n} \frac{q_{i_{n-1}, k}}{q_{i_{n-1}}},$$

则取 $X(\tau_n) = i_n, \dots$

如此继续重复如上步骤, 就可模拟 X 的一条轨道, 它满足已给的条件: 首先

$$P\{X(0) = i_0\} = P\left(\sum_{k=0}^{i_0-1} P_k(0) \leq U_0 < \sum_{k=0}^{i_0} P_k(0)\right) = P_{i_0}(0).$$

其次

$$P\{\theta_{n+1} \leq t | X(\tau_n) = i_n\} = P\{-q_{i_n}^{-1} \ln U_{n+1} \leq t\} = 1 - \exp(-q_{i_n} t).$$

最后

$$P\{X(\tau_{n+1}) = i_{n+1} | X(\tau_n) = i_n\} = P\left[\sum_{k=0}^{i_{n+1}-1} \frac{q_{i_n, k}}{q_{i_n}} \leq V_{n+1} < \sum_{k=0}^{i_{n+1}} \frac{q_{i_n, k}}{q_{i_n}}\right]$$

$$= q_{i_n, i_{n+1}} / q_{i_n}.$$

§ 6.6 可逆马氏链

对于一个随机过程, 有时沿时间逆向来考察它的概率特性也是很有意义的, 下面先给出一随机过程可逆性的定义.

定义 随机过程 $\{X(t), t \geq 0\}$, 对于任意 $0 \leq t_1 < t_2 < \cdots < t_n$, 记 $t'_k = t_1 + t_n - t_k$, 如果 $X(t_1), X(t_2), \cdots, X(t_n)$ 与 $X(t'_1), X(t'_2), \cdots, X(t'_n)$ 具有相同的联合概率分布, 即正向过程与逆向过程具有相同的概率特性, 则称该过程 $\{X(t), t \geq 0\}$ 是 **时间可逆的**. \square




图 6.6.1

可以借助于图 6.6.1 更好地理解时间可逆的概念. 正向时间序列的起点 t_1 与终点 t_n , 正好是逆向时间的终点 t'_n 与起点 t'_1 , 且沿正向看的相邻时间间隔与沿逆向看的时间间隔依次相同.

本节只讨论可逆马氏链的有关问题, 对于马氏链, 如何判断它是时间可逆的呢? 以下定理给出回答.

定理 6.6.1 设马氏链 $X = \{X(t), t \geq 0\}$, $P(t) = (P_{ij}(t))$, 具有平稳分布 $\{P_j, j \in S\}$, 初始分布为 $\{P_j(0), j \in S\}$, X 为时间可逆马氏链的充分必要条件是它是平稳过程 (即 $P_j = P_j(0), j \in S$), 且 $\forall t \geq 0, i, j \in S$ 有

$$P_i P_{ij}(t) = P_j P_{ji}(t). \quad (6.6.1)$$

证 必要性 设 X 是可逆 MC, 取 $n = 2, 0 < t_1 < t_2 = t_1 + t$, 由可逆定义有

$$P\{X(t_1) = i, X(t_1 + t) = j\} = P\{X(t_1 + t) = i, X(t_1) = j\} \quad (a)$$

上式两边对 j 求和, 得 $P(X(t_1) = i) = P(X(t_1 + t) = i)$, 知 X 为平稳过程, 记 $P_j = P(X(t) = j)$. 由 (a) 式可得 (6.6.1) 式.

212

充分性 设 (6.6.1) 式成立. $\forall 0 < t_1 < t_2 < \cdots < t_n$, 记 $t'_k = t_1 + t_n - t_k, 1 \leq k \leq n$, $\forall i_k \in S, 1 \leq k \leq n$.

6.6 可逆马氏链

$$\begin{aligned}
& P\{X(t_1) = i_1, X(t_2) = i_2, \dots, X(t_n) = i_n\} \\
&= P_{i_1} P_{i_1, i_2}(t_2 - t_1) P_{i_2, i_3}(t_3 - t_2) \cdots P_{i_{n-1}, i_n}(t_n - t_{n-1}) \\
&= P_{i_2, i_1}(t_2 - t_1) P_{i_3, i_2}(t_3 - t_2) \cdots P_{i_n, i_{n-1}}(t_n - t_{n-1}) P_{i_n} \\
&= P_{i_n} P_{i_n, i_{n-1}}(t_n - t_{n-1}) \cdots P_{i_3, i_2}(t_3 - t_2) P_{i_2, i_1}(t_2 - t_1) \\
&= P\{X(t_n + t_1 - t_n) = i_n, X(t_n + t_1 - t_n + t_n - t_{n-1}) = i_{n-1}, \dots, X(t_n + t_1 - t_1) = i_1\} \\
&= P\{X(t'_1) = i_1, X(t'_2) = i_2, \dots, X(t'_n) = i_n\}.
\end{aligned}$$

因此, X 为可逆 MC. \square

推论 1 对于马氏链 $X = \{X(t), t \geq 0\}$, 若存在分布 $\pi = (\pi_j, j \in S)$ 满足 (6.6.1), 则 π 是平稳分布, 若以 π 为初始分布, 则 X 是平稳过程.

证 对 (6.6.1) 式两边对 j 求和, 得

$$\pi_i = \sum_j \pi_i P_{ij}(t) = \sum_j \pi_j P_{ji}(t).$$

故 $\pi = \{\pi_j, j \in S\}$ 为平稳分布, 如 $\pi_j = P_j(0)$, 则 $P_j(0) = P\{X(t) = j\} = \sum_i \pi_i P_{ij}(t) = \pi_j$, 即 X 为平稳过程. \square

推论 2 离散参数马氏链 $X = \{X_n, n \geq 0\}$, $P = (P_{ij})$, $\pi_i = P(X_0 = i)$, $i \in S$, 则 X 可逆的充分必要条件为

$$\pi_i P_{ij} = \pi_j P_{ji} \quad (6.6.2)$$

证 必要性显然, 仅需证 (6.6.2) 式是可逆的充分条件, 用归纳法证对 $n \geq 1$ 均有

$$\pi_i P_{ij}^{(n)} = \pi_j P_{ji}^{(n)} \quad (b)$$

$n = 1$ 时, (b) 式即为 (6.6.2) 式. 现设 (b) 对 n 成立, 那么对 $n+1$ 有

$$\begin{aligned}
\pi_i P_{ij}^{(n+1)} &= \pi_i \sum_k P_{ik}^{(1)} P_{kj}^{(n)} \\
&= \sum_k P_{ki} \pi_k P_{kj}^{(n)} \\
&= \sum_k P_{ki} \pi_j P_{jk}^{(n)} \\
&= \pi_j \sum_k P_{jk}^{(n)} P_{ki} \\
&= \pi_j P_{ji}^{(n+1)}
\end{aligned}$$

213

从而 (b) 式对所有 $n \geq 1$ 成立. 再由推论 1, 知 π 是平稳分布, 且 X 是平稳过程. 再由定理 6.6.1 的充分性, 得 X 可逆. \square

对于连续参数马氏链 $X = \{X(t), t \geq 0\}$, 若给定的是密度矩阵 Q 矩阵, 自然希望将可逆性的条件用 Q 矩阵来描述.

定理 6.6.2 设平稳马氏链 X 的 Q 矩阵为 $Q = (q_{ij})$, 若满足向前向后微分方程的解唯一, 则 X 可逆的充要条件是平稳分布 $\pi = \{\pi_i, i \in S\}$ 满足

$$\pi_i q_{ij} = \pi_j q_{ji} \quad \forall i, j \in S \quad (6.6.3)$$

证 必要性显然, 下证充分性. 由 Q 满足

$$P'_{ij}(t) = \sum_k q_{ik} P_{kj}(t) = \sum_k P_{ik}(t) q_{kj},$$

令

$$\tilde{P}_{ij}(t) = \frac{\pi_j P_{ji}(t)}{\pi_i},$$

则

$$\begin{aligned} \tilde{P}'_{ij}(t) &= \frac{\pi_j}{\pi_i} P'_{ji}(t) \\ &= \sum_k \frac{\pi_j}{\pi_i} P_{jk}(t) q_{ki} \\ &= \sum_k \frac{\pi_j}{\pi_k} P_{jk}(t) \cdot \frac{\pi_k}{\pi_i} q_{ki} \\ &= \sum_k q_{ik} \tilde{P}_{kj}(t). \end{aligned}$$

可知 $(\tilde{P}_{ij}(t)) = \tilde{P}(t)$ 满足向后方程. 由解唯一性条件 $P_{ij}(t) = \tilde{P}_{ij}(t)$, 得

$$\pi_i P_{ij}(t) = \pi_j P_{ji}(t) \quad \forall i, j \in S, t \geq 0$$

由定理 6.6.1 知 X 可逆.

推论 1 若 X 为有限状态不可约平稳链, 则可逆的充要条件是 (6.6.3) 式成立.

对于生灭过程, 有如下重要定理

定理 6.6.3 对于给定生灭 Q 矩阵 (6.3.2), 若 $\lambda_k > 0 (k \geq 0)$, $\mu_k > 0, k \geq 1$, $\mu_0 = 0$, 则存在可逆生灭 Q 过程的充要条件是

$$\sum_{k=1}^{\infty} \frac{\lambda_0 \lambda_1 \cdots \lambda_{k-1}}{\mu_1 \mu_2 \cdots \mu_k} < \infty \quad (6.6.4)$$

证 (从略, 有兴趣的读者可看钱敏平, 侯振挺等著, 可逆马尔可夫过程, 1979 年湖南科学技术出版社).

可逆马氏链在物理, 生物, 排队网络中有广泛的应用, 以下仅举二个在排队论中的例子.

例1 M/M/s 排队系统

定理 6.6.4 在 M/M/s 排队系统中, 设顾客到达率为 $\lambda > 0$, 每个服务员的服务率为 $\mu > 0$, 若 $\lambda < s\mu$, 则顾客离开系统的输出过程在稳态下是参数为 λ 的 Poisson 流.

证 设 $X(t)$ 表示 t 时刻系统的顾客数, 显见 $X = \{X(t), t \geq 0\}$ 是生灭过程, 且由 $\frac{\lambda}{\mu s} < 1$ 知满足 (6.6.4) 式. 故 X 在稳态下是时间可逆的. 现沿时间正向看, $X = \{X(t), t \geq 0\}$ 过程增加 1 的时间点构成一参数为 λ 的 Poisson 过程, 这正是顾客相继到达时刻. 由过程可逆性, 当我们沿时间逆向看, $X(t)$ 增加 1 的时间点亦构成参数为 λ 的 Poisson 过程. 但这时间点恰是顾客相继离开的时刻, 从而顾客离开时间点构成速率为 λ 的 Poisson 过程 (如图 6.6.2 示). \square




图 6.6.2 \otimes 是沿逆向时间 $X(t)$ 增加 1 的时间点
它们恰是正向时间 $X(t)$ 减少的时间点

例2 串联排队系统

考虑一个具有二个服务台的排队串联系统. 设顾客以具有参数 λ 的 Poisson 流到达服务员 1 前, 经服务员 1 服务后, 它们加入到服务员 2 前的队列. 假设两个服务员前有无限的等待空间, 第 i 个服务员对每个顾客的服务时间是参数为 μ_i 的指数分布 ($i=1,2$), 此系统称为串联排队系统, 如图 6.6.3 所示




图 6.6.3

若 $\frac{\lambda}{\mu_1} < 1$, 则由定理 6.6.4 知服务员 1 的输出 (即服务员 2 前的到达) 过程是参数为 λ 的 Poisson 流, 故对第 2 个服务员而言, 也是 M/M/1 排队系统. 如若应用过程可逆性, 可得到进一步的结果. 先看

定理 6.6.5 在稳态遍历的 M/M/1 排队系统中, 则

- 1° 系统中现有顾客数与过去离开过程独立;
- 2° 顾客在系统的停留时间 (包括排队等待加上服务时间) 与它离开前的离去过程独立.

证 1° 因到达是 Poisson 流, 故以后到达的过程与现有系统的人数相互独立. 由

过程时间可逆性, 逆向时间的“未来到达过程”与系统的现有人数相互独立. 即正向时间看的“过去离开过程”与现有人数独立.

2° 设一顾客 T_1 时刻到, T_2 时刻离去, 由于顾客到达是 Poisson 流, 故顾客在系统的逗留时间 $T_2 - T_1$ 与 T_1 后到达的过程独立. 但逆向时间看, 等于一顾客 T_2 时间到, T_1 时间离开, 由过程时间可逆性, $T_2 - T_1$ 应独立于 T_2 “后” (逆向者) “到达过程”. 而这恰是正向时间 T_2 前的离开过程. \square

定理 6.6.6 若 $\frac{\lambda}{\mu_i} < 1 (i = 1, 2)$, 则串联排队系统在稳态下:

1° 在服务员 1 前的顾客数与服务员 2 前的顾客数相互独立, 且

$$P(\text{在 1 前有 } n \text{ 个, 在 2 前有 } m \text{ 个}) = \left(\frac{\lambda}{\mu_1}\right)^n \left(1 - \frac{\lambda}{\mu_1}\right) \left(\frac{\lambda}{\mu_2}\right)^m \left(1 - \frac{\lambda}{\mu_2}\right) \quad (6.6.5)$$

2° 一顾客在服务员 1 前的逗留时间与在服务员 2 前的逗留时间独立.

证 1° 由前一定理知, 服务员 1 前的顾客数独立于对 1 以往的离去过程, 这正是对 2 的到达过程, 从而两服务员前的顾客数独立, 于是 (6.6.5) 式得证.

2° 由前一定理, 一个顾客在服务员 1 前的逗留时间独立于它离开 1 前的离开过程, 而这恰是该顾客到达 2 前的到达过程 (对 2 而言). 从而每个顾客在 2 前的等待时间与服务员 2 对这些顾客的服务时间均独立于在服务员 1 的逗留时间. 故 2° 得证. \square

§ 6.7 马氏更新过程与半马氏过程

马氏更新过程是马氏过程与更新过程的综合和推广. 它有很强的背景: 设想一系统 (或一质点) 其状态的转移是随机的, 它从状态 i 出发转移到 (另一) 状态 j 的概率是 $Q(i, j)$, 相继到达 (访问) 的状态组成一马氏链. 同时, 它在每一状态的逗留时间是随机的, 其分布依赖于当前所处的状态及下一个将要到达的状态. 确切定义如下

定义 设 $X = \{X_n, n \geq 0\}$, 对固定的 $n \geq 0$, X_n 是取值于状态空间 $S = \{0, 1, 2, \dots\}$ 的随机变量. $T = \{T_n, n \geq 0\}$, T_n 是取值非负的随机变量, 且 $0 = T_0 \leq T_1 \leq T_2 \leq \dots \leq T_{n-1} \leq T_n \leq \dots$. 称过程 $\{X, T\} = \{(X_n, T_n), n \geq 0\}$ 为 **马氏更新过程**, 如若对 $\forall n \geq 0, j \in S, t \geq 0$ 满足

$$\begin{aligned} & P\{X_{n+1} = j, T_{n+1} - T_n \leq t | X_0, T_0, X_1, T_1, \dots, X_n, T_n\} \\ &= P\{X_{n+1} = j, T_{n+1} - T_n \leq t | X_n\} \end{aligned} \quad (6.7.1)$$

(6.7.1) 式表明, 已知现在状态 X_n , 将来状态 X_{n+1} 与停留在 X_n 的时间 $T_{n+1} - T_n$ 的联合分布与过去的历史 $X_0, T_0, \dots, X_{n-1}, T_{n-1}$ 独立. 称 (6.7.1) 式为半马尔可夫性. 本节讨论总假定 (T, X) 是时齐的, 即对任意 $i, j \in S, t \geq 0$

$$P(X_{n+1} = j, T_{n+1} - T_n \leq t | X_n = i) = Q(i, j, t)$$

6.7 马氏更新过程与半马氏过程

与 n 无关, 称矩阵族 $\{Q(t) = (Q(i, j, t)), t \geq 0\}$ 为半马氏核. 显然 $Q(i, j, t)$ 关于 t 是单调不减函数且右连续, 故

$$Q(i, j) \triangleq \lim_{t \rightarrow \infty} Q(i, j, t) = Q(i, j, \infty)$$

存在, 且 $Q(i, j) \geq 0, \sum_{j \in S} Q(i, j) = 1, i \in S$, 即 $Q = (Q(i, j))$ 是一随机矩阵.

以下几个命题反映马氏更新过程的基本特性.

设 $\{X, T\} = \{(X_n, T_n), n \geq 0\}$ 为马氏更新过程, $\{Q(t) = (Q(i, j, t)), t \geq 0\}$ 为其半马氏核.

命题 6.7.1 $X = \{X_n, n \geq 0\}$ 是 S 上转移矩阵为 $Q = (Q(i, j))$ 的马氏链.

证 由定义, 对 $\forall i, j \in S$, 易知

$$P\{X_{n+1} = j | X_0, X_1, \dots, X_n = i\} = P\{X_{n+1} = j | X_n = i\} = Q(i, j)$$

令 $G(i, j, t) = Q(i, j, t)/Q(i, j)$, 显然

$$P\{T_{n+1} - T_n \leq t | X_n = i, X_{n+1} = j\} = G(i, j, t). \quad \square$$

表明在 $X_n = i$ 的停留时间分布不仅与现在时刻 i 而且与下一步转移到的状态 $X_{n+1} = j$ 有关. 可见连续参数马氏链是它的特殊情形.

命题 6.7.2 $\forall n > 1, t_1, t_2, \dots, t_n \geq 0$, 则

$$\begin{aligned} P(T_1 - T_0 \leq t_1, T_2 - T_1 \leq t_2, \dots, T_n - T_{n-1} \leq t_n | X_0, X_1, \dots, X_n) \\ = G(X_0, X_1, t_1)G(X_1, X_2, t_2) \cdots G(X_{n-1}, X_n, t_n) \end{aligned} \quad (6.7.2)$$

即给定 $\{X_n, n \geq 0\}$ 时, 逗留时间序列 $\{\theta_n = T_n - T_{n-1}, n \geq 1\}$ 条件独立, 特别是, 若 S 只有一个状态时, 则 $\{\theta_n, n \geq 1\}$ 独立同分布.

证 用数学归纳法. \square

推论 若 S 只由一个状态组成, 则 $T = \{T_n, n \geq 1\}$ 是一更新过程.

可见, 马氏更新过程是更新过程的推广.

有时, 人们关心的是到达某状态的性态. 设 $j \in S$ 固定, 令

$$\begin{aligned} S_0^j &= \min\{n : n \geq 0, X_n = j\} \\ S_n^j &= \min\{n : n > S_{n-1}^j, X_n = j\} \quad n \geq 1. \end{aligned}$$

S_n^j 是第 n 次访问 j 的时刻, $S_n^j - S_{n-1}^j$ 是第 n 次与第 $n-1$ 次访问 j 的时间间隔.

命题 6.7.3 令 $j \in S$ 固定, 则 $S^j = \{S_n^j, n \geq 0\}$ 是延时更新过程, 即 $S_0^j, S_1^j - S_0^j, \dots, S_{n+1}^j - S_n^j, \dots$ 相互独立, 且 $\{S_n^j - S_{n-1}^j, n \geq 1\}$ 同分布.

其证明由命题 6.7.2 的推论及下面命题 6.7.4 即得.

在马氏更新过程中, 允许 $T_n = +\infty$, $X_\infty = \infty$, 为使状态空间 S 紧化, 在 S 中增加一新的状态, 记为 ∞ . 设对状态子集 $H \subset S$, 记

$$\tau_0 = \min\{n : n \geq 0, X_n \in H\}$$

$$\tau_n = \min\{n : n > \tau_{n-1}, X_n \in H\} \quad n \geq 1$$

$$\tilde{X}_n = X_{\tau_n}, \tilde{T}_n = T_{\tau_n}, (\tilde{X}, \tilde{T}) = \{(\tilde{X}_n, \tilde{T}_n), n \geq 0\}$$

命题 6.7.4 $(\tilde{X}, \tilde{T}) = \{(\tilde{X}_n, \tilde{T}_n), n \geq 0\}$ 是状态空间为 $H \cup \{+\infty\}$ 的马氏更新过程.
(证明从略).

给定马氏更新过程 $(X, T) = \{(X_n, T_n), n \geq 0\}$. $\forall t \geq 0$, 令

$$Y(t) = \begin{cases} X_n & T_n \leq t < T_{n+1} \\ \infty & t > \sup_n T_n \end{cases}$$

称 $Y = \{Y(t), t \geq 0\}$ 为由马氏更新过程 (X, T) 产生的 (最小) 半马氏过程.

显然, Y 是连续参数随机过程, 是否是马氏过程呢? 一般情况下回答是否定的. 但是在其更新点 $\{T_n, n \geq 0\}$ 上 $\{Y(T_n) = X_n, n \geq 0\}$ 是一马氏链, 故我们称 $Y = \{Y(t), t \geq 0\}$ 为半马氏过程.

例 M/G/1 排队系统. 即顾客到达流是参数为 λ 的 Poisson 流, 服务员对每位顾客的服务时间独立同分布, 分布函数为 $G(x)$, 且与到达流独立. 令 $T_0 = 0$, T_n 表第 n 个顾客离开时刻 ($n \geq 1$), X_n 为第 n 个顾客离开时刻 T_n^+ 系统中的顾客数. 先证 $(X, T) = \{(X_n, T_n), n \geq 0\}$ 是状态空间 $S = \{0, 1, 2, \dots\}$ 的马氏更新过程.

证

$$\begin{aligned} & P(X_{n+1} = j, T_{n+1} - T_n \leq t | X_0, T_0, \dots, X_n, T_n) \\ &= \int_0^t P(X_{n+1} = j | X_0, T_0, \dots, X_n, T_n, T_{n+1} - T_n = u) \\ & \quad dP(T_{n+1} - T_n \leq u | X_0, T_0, \dots, X_n, T_n) \text{ (对 } T_{n+1} - T_n \text{ 使用全概率公式)} \\ &= \int_0^t P(X_{n+1} = j | X_n, T_{n+1} - T_n = u) dG(u) \\ & \quad \text{(} X_{n+1} \text{ 只与 } X_n \text{ 时数目和间隔 } u \text{ 有关. 服务时间相互独立,} \\ & \quad \text{且与到达过程独立.)} \\ &= \int_0^t P(X_{n+1} = j, T_{n+1} - T_n \leq t | X_n, T_{n+1} - T_n = u) dP(T_{n+1} - T_n \leq u | X_n) \\ &= P(X_{n+1} = j, T_{n+1} - T_n \leq t | X_n) \quad \square \end{aligned}$$

(X, T) 的半马氏核 $Q(t) = (Q(i, j, t))$ 如下:

$$Q(t) = \begin{vmatrix} P_0(t) & P_1(t) & P_2(t) & P_3(t) & \cdots \\ q_0(t) & q_1(t) & q_2(t) & q_3(t) & \cdots \\ 0 & q_0(t) & q_1(t) & q_2(t) & \cdots \\ 0 & 0 & q_0(t) & q_1(t) & \cdots \\ \vdots & \ddots & & & \end{vmatrix}$$

这里

$$q_n(t) = \int_0^t \frac{(\lambda x)^n}{n!} e^{-\lambda x} dG(x),$$

$$P_n(t) = \int_0^t \lambda e^{-\lambda x} q_n(t-x) dx, n = 0, 1, 2, \dots.$$

推导如下: 记 $\theta_n = T_n - T_{n-1}$, 则 $Q(i, j, t) = P(X_n = j, \theta_n \leq t | X_{n-1} = i)$, 当 $i \geq 1, j \geq i-1$ 时, 利用全概率公式

$$\begin{aligned} Q(i, j, t) &= \int_0^t P\{X_n = j, \theta_n \leq t | X_{n-1} = i, \theta_n = x\} dG(x) \\ &= \int_0^t P\{\text{在 } [0, x] \text{ 上恰好到达 } j-i+1 \text{ 个顾客} | X_{n-1} = i, \theta_n = x\} dG(x) \\ &= \int_0^t \frac{(\lambda x)^{j-i+1}}{(j-i+1)!} e^{-\lambda x} dG(x) = q_{j-i+1}(t) \end{aligned}$$

当 $i = 1$ 时, $Q(1, j, t) = q_j(t)$. 显然, 当 $i \geq 1, j < i-1$ 时, $Q(i, j, t) = 0$.

$Q(i, j, t) = q_j(t)$ 的直观意义: 不妨设 T_{n-1}^+ 时 $X_{n-1} = i = 1$. 这表示 T_{n-1}^+ 时刻第 $n-1$ 个顾客离开之前第 n 个顾客已经到达, 因而在 T_{n-1}^+ 时立即被服务, 而第 $n+1$ 个顾客在 T_{n-1}^+ 之后才到达. 于是 $q_j(t) = Q(i, j, t)$ 表示在 T_{n-1}^+ 时, 第 n 顾客开始被服务的条件下, 该顾客在 t 时刻之前 (包括 t 时刻) 被服务完毕离去且离去时刻 T_n^+ 时系统的顾客数恰为 j 个 (即 $X_n = j$) 的概率.

若 $X_{n-1} = i = 0$, 表示系统在 T_{n-1}^+ 开始空闲, 且第 n 个顾客是在 T_{n-1}^+ 之后的某时刻到达, 记 S_n 为第 n 个顾客到达时刻与时刻 T_{n-1} 的时间间隔, 则

$$\begin{aligned} Q(0, j, t) &= P\{X_n = j, \theta_n \leq t | X_{n-1} = i\} \\ &= \int_0^t P\{X_n = j, \theta_n \leq t | X_{n-1} = 0, S_n = x\} \lambda e^{-\lambda x} dx \\ &= \int_0^t Q(1, j, t-x) \lambda e^{-\lambda x} dx \\ &= \int_0^t q_j(t-x) \lambda e^{-\lambda x} dx \\ &= P_j(t). \end{aligned}$$

§ 6.8 连续时间马氏链与离散时间马氏链首达目标模型的关系

在连续时间马氏链的理论与应用中, 我们往往对其过程的不同性质指标感兴趣. 已有的研究表明, 求解这些性能指标, 大都可以化为求解某些意义等价的离散时间首达目标可加泛函的一阶矩问题. 这为连续参数马氏链的离散化提供了新的途径.

设连续参数马氏链 $X = \{X(t), t \geq 0\}$, 状态空间 $\tilde{S} = \{1, 2, \dots, m, 0\} = S \cup S_0$, $S = \{1, 2, \dots, m\}$, $S_0 = \{0\}$, 转移率矩阵 $\tilde{Q} = (q_{ij})$, $i, j \in \tilde{S}$ 为保守 Q 矩阵. $r: S \rightarrow \mathbb{R}^+$, r 为性能函数 (或费用函数), $r(i) = r_i$ 表示过程在 i 状态的性能 (或费用), 不失一般性, 设 $i \in S$ 时, $r_i > 0$, $i \in S_0$ 时, $r_i = 0$. 令 $\tau_1 = \inf\{t: t > 0, X(t) \neq X(0)\}$ 为第一次跳跃时间. $\tau = \inf\{t: t > 0, X(t) \in S_0\}$, 规定: $\inf \phi = +\infty$. 若 $X(0) \in S_0$, $\tau = 0$. τ 表示过程从 S 到 S_0 的首达时间.

试举几种问题加以讨论.

1. 首达时间与首达目标积分型泛函

令 $W = \int_0^\tau e^{-\alpha t} r(X(t)) dt$ (其中, $\alpha > 0$ 为折扣率因子), $\mu_k(i) = E(W^k | X(0) = i)$, $k \geq 0$, $i \in \tilde{S}$, $M = \max_{i \in \tilde{S}} r_i$. 显然, 当 $i \in S_0$ 时, $\mu_k(i) = 0$; 当 $i \in S$, $q_i = 0$ 时, $\mu_k(i) = (\int_0^\infty e^{-\alpha t} r(i) dt)^k = (\alpha^{-1} r_i)^k$. 下面仅讨论 $i \in S$ 的情形, 记 $W_{\tau_1} = \int_{\tau_1}^\tau e^{-\alpha(t-\tau_1)} r(X(t)) dt$, 易知, $X(0) \in S$ 时,

$$W = \begin{cases} \alpha^{-1} r(X(0))(1 - e^{-\alpha \tau_1}) & X(\tau_1) \in S_0. \\ \alpha^{-1} r(X(0))(1 - e^{-\alpha \tau_1}) + e^{-\alpha \tau_1} W_{\tau_1} & X(\tau_1) \in S. \end{cases} \quad (6.8.1)$$

记 $P_{ij} \triangleq P(X(\tau_1) = j | X(0) = i) = \delta_{ij} + q_{ij}/q_i$, $P = (P_{ij})$, $i, j \in S$. $\beta_k(i) = q_i(k\alpha + q_i)$, $\beta_0 \circ P = (\beta_k(i)P_{ij})$, $i, j \in S$. $R_k(i) = (k\alpha + q_i)^{-1} k r(i) \mu_{k-1}(i)$, $R_k = (R_k(i), i \in S)^T$, $\mu_k = (\mu_k(i), i \in S)^T$. 易知, $0 < \beta_1(i) < 1$, $0 < \sum_{j \in S} \beta_k(i) P_{ij} \leq \beta_1(i) < 1$. 我们有

定理 6.8.1

$$\mu_1(i) = R_1(i) + \beta_1(i) \sum_{j \in S} P_{ij} \mu_1(j), i \in S \quad (6.8.2)$$

即

$$\mu_1 = R_1 + \beta_1 \circ P \cdot \mu_1 \quad (6.8.3)$$

220

$$\mu_1 = \sum_{n=0}^{\infty} (\beta_1 \circ P)^n R_1 \quad (6.8.4)$$

6.8 连续时间马氏链与离散时间马氏链首达目标模型的关系

证 对 $\forall i \in S$

$$\begin{aligned}
 \mu_1(i) &= E(\alpha^{-1}r(X(0))(1 - e^{-\alpha\tau_1})|X(0) = i) + \sum_{j \in S} P_{ij} E(e^{-\alpha\tau_1} W_{\tau_1} | X(0) = i, X(\tau_1) = j) \\
 &= \alpha^{-1}r_i(\alpha + q_i)^{-1} + \sum_{j \in S} P_{ij} E(e^{-\alpha\tau_1} | X(0) = i, X(\tau_1) = j) E(W_{\tau_1} | X(0) = i, \\
 &\quad X(\tau_1) = j) \quad (\text{由强马氏性, } e^{-\alpha\tau_1} \text{ 与 } W_{\tau_1} \text{ 关于 } X(0) = i, X(\tau_1) = j \text{ 条件独立}) \\
 &= R_1(i) + \sum_{j \in S} P_{ij} E(e^{-\alpha\tau_1} | X(0) = i) E(W_{\tau_1} | X(\tau_1) = j) \\
 &\quad (\text{由于 } \tau_1 \text{ 与 } X(\tau_1) \text{ 关于 } X(0) = i \text{ 条件独立及强马氏性}) \\
 &= R_1(i) + E(e^{-\alpha\tau_1} | X(0) = i) \sum_{j \in S} P_{ij} \mu_1(j) \\
 &\quad (\text{因为 } E(W_{\tau_1} | X(\tau_1) = j) = E(W | X(0) = j)) \\
 &= R_1(i) + q_i(\alpha + q_i)^{-1} \sum_{j \in S} P_{ij} \mu_1(j)
 \end{aligned}$$

得 $\mu_1(i) = R_1(i) + \beta_1(i) \sum_{j \in S} P_{ij} \mu_1(j)$, 写成向量形式, 即有 (6.8.3) 式. 注意到, $\beta_1 \circ P$ 的谱半径 $0 < \rho(\beta_1 \circ P) \leq \max_{i \in S} [q_i/(\alpha + q_i)] < 1$, 故由 (6.8.3) 式逐次迭代, 有

$$\begin{aligned}
 \mu_1 &= R_1 + \beta_1 \circ P(R_1 + \beta_1 \circ P \cdot \mu_1) = R_1 + (\beta_1 \circ P)R_1 + (\beta_1 \circ P)^2 \mu_1 = \cdots \\
 &= \sum_{k=0}^n (\beta_1 \circ P)^k R_1 + (\beta_1 \circ P)^{n+1} \mu_1
 \end{aligned}$$

因为 $n \rightarrow +\infty$, $(\beta_1 \circ P)^{n+1} \mu_1 \rightarrow 0$, 即得 (6.8.4) 式. □

为了讨论 $k \geq 2$ 的情形, 先给出两个引理.

引理 6.8.1 $\forall k \geq 1, i \in S$, 当 $q_i > 0$ 时有

$$\begin{aligned}
 \mu_k(i) &= (\alpha^{-1}r_i)^k \sum_{m=0}^k C_k^m (-1)^m q_i(m\alpha + q_i)^{-1} + \sum_{l=1}^{k-1} \left\{ C_k^l (\alpha^{-1}r_i)^{k-l} \cdot \sum_{m=0}^{k-l} \right. \\
 &\quad \left. C_{k-l}^m (-1)^m q_i((m+l)\alpha + q_i)^{-1} \cdot \left(\sum_{j \in S} P_{ij} \mu_l(j) \right) \right\} + q_i(k\alpha + q_i)^{-1} \sum_{j \in S} P_{ij} \mu_k(j). \quad (8.8)
 \end{aligned}$$

证 注意到当 $X(0) = i \in S, X(\tau_1) = j \in S_0$ 时, 有

$$\begin{aligned}
 W^k &= [\alpha^{-1}r_i(1 - e^{-\alpha\tau_1}) + e^{-\alpha\tau_1} W_{\tau_1}]^k \quad (\text{二项式展开}) \\
 &= (\alpha^{-1}r_i)^k \sum_{m=0}^k C_k^m (-1)^m e^{-\alpha m \tau_1} \\
 &\quad + \sum_{l=1}^{k-1} C_k^l (\alpha^{-1}r_i)^{k-l} \left[\sum_{m=0}^{k-l} C_{k-l}^m (-1)^m e^{-\alpha m \tau_1} \right] e^{-\alpha l \tau_1} W_{\tau_1}^l + e^{-\alpha k \tau_1} W_{\tau_1}^k
 \end{aligned}$$

于是, 类似于定理 6.8.1 对 $k = 1$ 的证明, 有

$$\begin{aligned}
 \mu_k(i) &= E(W^k | X(0) = i) \\
 &= (\alpha^{-1} r_i)^k \cdot \sum_{m=0}^k C_k^m (-1)^m q_i (m\alpha + q_i)^{-1} \\
 &\quad + \sum_{l=1}^{k-1} \left\{ C_k^l (\alpha^{-1} r_i)^{k-l} \cdot \sum_{m=0}^{k-l} C_{k-l}^m (-1)^m E[e^{-\alpha(m+l)\tau_1} | X(0) = i] \cdot \right. \\
 &\quad \left. \sum_{j \in S} P_{ij} E(W_{\tau_1}^l | X(0) = i, X(\tau_1) = j) \right\} + q_i (k\alpha + q_i)^{-1} \sum_{j \in S} P_{ij} \mu_k(j)
 \end{aligned}$$

即得 (6.8.5) 式. \square

引理 6.8.2 $\forall k \geq 1$,

$$\sum_{m=0}^k C_k^m (-1)^m (m\alpha + q_i)^{-1} = k! \alpha^k \prod_{m=0}^k (m\alpha + q_i)^{-1} \quad (6.8.6)$$

证 用归纳法可证. \square

定理 6.8.2 $\forall k \geq 1, q_i > 0$,

$$\mu_k(i) = (k\alpha + q_i)^{-1} k r_i \mu_{k-1}(i) + q_i (k\alpha + q_i)^{-1} \sum_{j \in S} P_{ij} \mu_k(j) \quad (6.8.7)$$

$$\text{即 } \mu_k(i) = R_k(i) + \beta_k(i) \sum_{j \in S} P_{ij} \mu_k(j) \quad (6.8.8)$$

$$\text{且 } \mu_k = \sum_{n=0}^{\infty} (\beta_k \circ P)^n R_k \quad (6.8.9)$$

证 利用归纳法及引理 6.8.1, 引理 6.8.2.

当 $k = 1$ 时, 公式 (6.8.7) 即为 (6.8.2). 现设 (6.8.7) 式对 $1 \leq k \leq n$ 均成立, 即对 $1 \leq l \leq n$, 有

$$q_i \sum_{j \in S} P_{ij} \mu_l(j) = (l\alpha + q_i) \mu_l(i) - l r_i \mu_{l-1}(i) \quad (6.8.10)$$

以 (6.8.10) 及 (6.8.6) 式代入 (6.8.5) 式, 对 $k = n+1$ 的情形 (并注意到 $C_{n+1}^{l+1} C_{l+1}^l = C_{n+1}^l (n+1-l)$, $\mu_0(i) = 1$), 有

$$\begin{aligned}
 \mu_{n+1}(i) &= r_i^{n+1} (n+1)! \prod_{m=0}^{n+1} (m\alpha + q_i)^{-1} + \sum_{l=1}^{n+1-l} C_{n+1}^l r_i^{n+1-l} (n+1-l)! \\
 &\quad \prod_{m=0}^{n+1-l} ((m+l)\alpha + q_i)^{-1} [(l\alpha + q_i) \mu_l(i) - l r_i \mu_{l-1}(i)] + q_i ((n+1)\alpha + q_i)^{-1} \\
 &\quad \sum_{j \in S} P_{ij} \mu_{n+1}(j) \\
 &= [(n+1)\alpha + q_i]^{-1} (n+1) r_i \mu_n(i) + q_i [(n+1)\alpha + q_i]^{-1} \sum_{j \in S} P_{ij} \mu_{n+1}(j)
 \end{aligned}$$

6.9 首达时间与首达目标积分型泛函的特性及其反问题

故 (6.8.7) 式对 $k \geq 1$ 均成立. 由 (6.8.7) 式即得 (6.8.8) 式. □

通过比较 (6.8.8) 式与 (6.9.2) 式知, μ_k 与 μ_1 有相同的代数结构.

2. 折扣积分型泛函

当 S 为闭集时, 则当 $\forall X(0) = i \in S$ 时, $P(\tau = +\infty | X(0) = i) = 1$. 此时, $W = \int_0^\infty e^{-\alpha t} r(X(t)) dt$ 化为折扣积分型泛函. 不难看出, $\mu_k(i) = E(W^k | X(0) = i), i \in S$ 仍满足定理 6.8.2.

3. 首达时间与首达目标积分型泛函

当取 $\alpha = 0$, 则 $W = \int_0^\tau r(X(t)) dt$ 是首达目标 (非折扣) 积分型泛函. 当取 $r(i) = 1$ 时, $W = \tau$ 就是从 S 到 S_0 的首达时间. 这一类问题在理论与应用上更有意义. 我们将在下面更详细地讨论它们.

连续时间积分型泛函 k 阶矩可以化为离散时间首达目标一阶矩问题. 以上几种连续时间积分型泛函求解 k 阶矩问题, 均可转化为求解离散时间首达目标可加泛函的一阶矩问题. 确切叙述如下:

设 $M.C.\tilde{X} = \{\tilde{X}_n, n \geq 0\}$, 状态空间 $\tilde{S} = S \cup S_0$, 其中, $S = \{1, 2, \dots, m\}$, $S_0 = \{\delta\}$. 一步转移概率矩阵 $\tilde{P} = (\tilde{P}_{ij}), i, j \in S$. $R(i)$ 表示系统在 i 状态的性能指标, 称 $R: \tilde{S} \rightarrow \mathbb{R}$ 为性能函数, $T = \inf\{n: n \geq 0, X(n) = \delta\}$ 为从 S 到 S_0 的首达时间. 令 $W_0 = \sum_{n=0}^T R(X_n)$, $\tilde{\mu}_1(i) = E(W_0 | X_0 = i)$, 由第三章 § 6 知, 当 S 为瞬态集时, $\tilde{\mu} = (I - \tilde{P})^{-1}R$ 是方程 $X = R + \tilde{P}X$ 的唯一解 (非负最小解). 一般地, 对求解 $\mu_k (k \geq 1)$ 我们有以下定理: 当取 $\tilde{R}(i) = R_k(i)$, $\tilde{P}_{ij} \triangleq \beta_k(i)P_{ij}, i, j \in S$, $\tilde{P}_{i\delta} = 1 - \sum_{j \in S} \tilde{P}_{ij}$, $\tilde{P}_{\delta\delta} = 1$, $\tilde{P}_{\delta j} = 0, j \in S$, 则 $\tilde{\mu}_1 = \mu_k$. 这说明求连续时间的积分型泛函的 k 阶矩可以转化为离散时间首达目标可加泛函的一阶矩问题. 类似的情形很多, 这里不一一列举.

§ 6.9 首达时间与首达目标积分型泛函的特性及其反问题

连续时间马氏链的首达时间及首达目标积分型泛函有其广泛的应用背景, 例如系统的使用寿命, 人工神经网络训练达到要求的时间, 排队系统中的队长与忙期, 通讯中信号的堵塞时间, 水坝水位超过警戒线的时刻等等, 无不与首达时间或首达目标相联系. 本节着重讨论首达时间的分布、生成函数及其矩的关系, 及马氏链的反问题.

我们考虑连续时间 $M.C.X = \{X(t), t \geq 0\}$, 在状态空间 $\tilde{S} = \{1, 2, \dots, m, m+1, m+2, \dots\} = S \cup S_0$ (其中 $S = \{1, 2, \dots, m\}$, $S_0 = \tilde{S} - S = \{m+1, m+2, \dots\}$), 其转移率矩阵 $\tilde{Q} = (q_{ij}), i, j \in S$ (\tilde{Q} 亦称为无穷小生成算子), $\tilde{Q}_{223} = \begin{pmatrix} Q & q_0 \\ 0 & 0 \end{pmatrix}$, 其中 Q 是 $m \times m$ 矩阵, $q_{ij} \geq 0, j \neq i, q_i = -q_{ii} \geq 0, 0 \leq \sum_{j \neq i} q_{ij} \leq q_i < \infty$, 且 $q_0 + Qe = 0, e = (1, 1, \dots, 1)'$, $0 = (0, 0, \dots, 0)'$ 分别是 S 上的单位列向量, 零列向量. $\tau_1 = \inf\{t: t > 0, X(t) \neq X(0)\}$,

$\tau = \inf\{t : t > 0, X(t) \in S_0\}$, 易知 τ 是从状态集 S 到 S_0 的首达时间. 规定 $\inf \phi = +\infty$, $\tau = 0$ (若 $X(0) \in S_0$). $r: \tilde{S} \rightarrow \mathbb{R}^+$, $r(i)$ 表示系统在 i 状态对应的性能指标, 不失一般性, 设 $r(i) > 0, i \in S$; $r(i) = 0, i \in S_0$. 取 $S_0 = \{0\}$, 此时 $\tilde{Q} = (q_{ij}), i, j \in \tilde{S}$, 保守. 记 $W = \int_0^\tau r(X(t)) dt$ 为首达目标积分泛函.

本节将研究 τ 与 W 的矩与它们的分布函数, 及其 Laplace-Stieltjes 变换 (亦称生成函数) 的关系. 为避免平凡情况, 在本节我们设 M.C.X 从 S 到 S_0 以概率 1 可达. 即设

$$P(\tau < +\infty | X(0) = i) = 1, \quad \forall i \in S \quad (6.9.1)$$

成立. 为了便于检验 (6.9.1) 式是否成立, 我们先给出以下几个引理:

引理 6.9.1 从 S 出发以概率 1 可达 S_0 的必要条件是 S 中没有吸收状态, 即 (6.9.1) 式成立的必要条件是 $\forall i \in S, q_i > 0$.

证 记 $\tau_1 = \inf\{t : t > 0, X(t) \neq X(0)\}$, 用反证法, 若 $\exists i \in S$ 使 $q_i = 0$, 则 $P(\tau_1 = +\infty | X(0) = i) = 1$, 因为 $\{\tau_1 = +\infty, X(0) = i\} \subset \{\tau = +\infty, X(0) = i\}$, 得 $1 = P\{\tau_1 = +\infty | X(0) = i\} \leq P(\tau = +\infty | X(0) = i) \leq 1 \rightarrow P(\tau = +\infty | X(0) = i) = 1$, 这与假设 $\forall i \in S, P(\tau < \infty | X(0) = i) = 1$ 相矛盾. \square

引理 6.9.2 (6.9.1) 式成立的充要条件是限制在 S 上的 Q 矩阵 $Q = (q_{ij}), i, j \in S$ 非奇异.

证 记 $f_i = P(\tau < \infty | X(0) = i), i \in S, f = (f_i, i \in S)'$, $P_{i0} = q_i^{-1}q_{i0}, q_0 \triangleq (q_{i0}, i \in S)'$. 由全概率公式及强马氏性, 有 $f_i = q_i^{-1}q_{i0} + \sum_{j \neq i, j \in S} q_i^{-1}q_{ij}f_j, i \in S$, 写成向量形式, 并注意到 $q_0 = -Qe, e = (1, 1, \dots, 1)'$, 即有

$$Qf = Qe \quad (6.9.2)$$

若 Q 非奇异, 即 Q^{-1} 存在, 则 $f = e$ 是 (6.9.2) 的唯一解. 即 $f_i = P(\tau < \infty | X(0) = i) = 1, \forall i \in S$.

下证当 $f = e$ 时, Q 非奇异. 用反证法, 假设 Q 奇异, 则存在一非负、非零的行向量 $v, vT = 0$. 故对所有 $t \geq 0$, 有 $ve^{Qt}e = ve > 0$, 且向量 $u \triangleq \lim_{t \rightarrow \infty} e^{Qt}e \neq 0$, 从而 $vu = ve > 0$. 这表明至少存在一状态 $i \in S$, 使得 $f_i = 1 - u_i < 1$, 矛盾. 故 Q 非奇异. \square

令 $P_{ij} = \delta_{ij} + q_i^{-1}q_{ij}, P = (P_{ij}), i, j \in S, \rho_0 = \rho(P)$ 为 P 的谱半径. 进一步我们有

引理 6.9.3 下面命题等价: 1° $f = e$; 2° Q^{-1} 存在; 3° X 在 S 中无任何闭子集; 4° $\rho_0 < 1$; 5° $J_1 < +\infty$.

证 (略. 有兴趣的读者可以作为练习自己证明).

$$\text{记 } M_k(i_1, i_2, \dots, i_k) = \begin{pmatrix} q_{i_1 i_1} & q_{i_1 i_2} & \cdots & q_{i_1 i_k} \\ q_{i_2 i_1} & q_{i_2 i_2} & \cdots & q_{i_2 i_k} \\ \vdots & \vdots & \ddots & \vdots \\ q_{i_k i_1} & q_{i_k i_2} & \cdots & q_{i_k i_k} \end{pmatrix} \quad \text{为由矩阵 } Q = (q_{ij}) \text{ 的第 } i_1, i_2, \dots, i_k$$

6.9 首达时间与首达目标积分型泛函的特性及其反问题

行与第 i_1, i_2, \dots, i_k 列的交叉元素构成的 k 阶子矩阵, $1 \leq k \leq m, 1 \leq i_1 < i_2 < \dots < i_k \leq n, d_k(i_1, i_2, \dots, i_k) = (-1)^k \det M_k(i_1, i_2, \dots, i_k)$.

引理 6.9.4 当 (6.9.1) 式成立时, 有 $(-1)^k \cdot d_k(i_1, i_2, \dots, i_k) > 0, \forall 1 \leq k \leq m, 1 \leq i_1 < i_2 < i_3 < \dots < i_k \leq m$, 即 $-M_k$ 是 Minkoski 矩阵.

证 注意到当 (6.9.1) 式成立时, S 中没有任何闭子集, 故任取 $S_k = \{i_1, i_2, \dots, i_k\} \subset S$, 对 $\forall 1 \leq k \leq m, 1 \leq i_1 < i_2 < \dots < i_k \leq m$, 则从 S_k 必以概率 1 到达 $S_k^0 = \tilde{S} - S_k$. 这表明 Q 的主子矩阵 $M_k(i_1, i_2, \dots, i_k)$ 为对角占优不可约矩阵, 且至少有一行对角严格占优, 可知 M_k 非奇异. 再由有关矩阵分析及行列式性质即得 $(-M_k)$ 是 Minkoski 矩阵, 且 $(-1)^k d_k(i_1, i_2, \dots, i_k) = \det(-M_k(i_1, i_2, \dots, i_k)) > 0$.

本节以下均在 (6.9.1) 式成立下讨论. 令 $Q_d = \text{diag}(q_i, i \in S), M_0 = \max_{i \in S} r(i), J_k(i) = E(\tau^k | X(0) = i), \bar{J}_k(i) = E(W^k | X(0) = i), i \in S, \mathbf{J}_k = (J_k(i), i \in S)', \bar{\mathbf{J}}_k = (\bar{J}_k(i), i \in S)', J_k = \alpha \mathbf{J}_k, \bar{J}_k = \alpha \bar{\mathbf{J}}_k$.

定理 6.9.1

1° $\forall k \geq 1, \mathbf{J}_k, \bar{\mathbf{J}}_k$ 满足方程:

$$\mathbf{J}_k = kQ_d^{-1}\mathbf{J}_{k-1} + Q_d^{-1}(Q + Q_d)\mathbf{J}_k, \quad \bar{\mathbf{J}}_k = kQ_d^{-1}\bar{\mathbf{J}}_{k-1} + Q_d^{-1}(Q + Q_d)\bar{\mathbf{J}}_k \quad (6.9.3)$$

2°

$$\mathbf{J}_k = (-1)^k k! Q^{-1} e, \quad \bar{\mathbf{J}}_k = -kQ^{-1}(\bar{\mathbf{J}}_{k-1} \circ r), \text{ 其中 } \bar{\mathbf{J}}_k \circ r = (\bar{J}_k(i)r(i), i \in S)' \quad (6.9.4)$$

3°

$$|\mathbf{J}_k| \leq k! \rho_0^{-k}, \quad |\bar{\mathbf{J}}_k| \leq k! \rho_0^{-k} M_0^k \quad (6.9.5)$$

证 1° : 注意到在 § 6.8 定理 6.8.2 的式 (6.8.7) 中, 当 $\alpha = 0$ 时, 即得 (6.9.3) 式.

2°、3° : 由 (6.9.3) 立得 (6.9.4) 及 (6.9.5) 式. □

令: $F_i(x) = P(\tau \leq x | X(0) = i), \bar{F}_i(x) = P(W \leq x | X(0) = i), i \in S, x \geq 0, s \geq 0. F(x) = \sum_{i=1}^m \alpha_i F_i(x), \bar{F}(x) = \sum_{i=1}^m \alpha_0 \bar{F}_i(x).$

记 $G_i(x) = P(\tau_1 \leq x | X(0) = i) = (1 - e^{-q_i x}) I_{(x \geq 0)}, r(i) \triangleq r_i$. 对 $F_i(x), \bar{F}_i(x)$ 有

定理 6.9.2

$$F_i(x) = q_i^{-1} q_{i0} G_i(x) + q_i^{-1} \sum_{j \neq i, j \in S} q_{ij} \int_0^x F_j(x-u) dG_i(u) \quad (6.9.6)$$

$$\bar{F}_i(x) = q_i^{-1} q_{i0} G_i(xr^{-1}(i)) + q_i^{-1} \sum_{j \neq i, j \in S} q_{ij} \int_0^{xr_i^{-1}} \bar{F}_j(x - ur_i) dG_i(u) \quad (6.9.7)$$

证 令 $\tau' = \inf\{t : t > 0, X(\tau_1 + t) \in S_0\}$, $X(\tau_1 + t) = X(\tau_1 + t)$, 则 $\tau = \tau_1 + \tau'$. 注意到 τ_1 与 $X(\tau_1)$ 关于 $X(0) = i$ 条件独立, τ_1 与 $X(\tau_1 + t)$ 关于 $X(0) = i$ 条件独立. 再由全概率公式与强马氏性, 即可得 (6.9.6) 及 (6.9.7). (可参考上节定理 6.8.1 的证明.)

注意到, 若令 $\bar{q}_{ij} = q_{ij}r_i^{-1}$, $\bar{G}_i(x) = G_i(xr_i^{-1}) = (1 - e^{-q_i r_i^{-1}x})I_{(x \geq 0)}$, $\bar{Q} = (\bar{q}_{ij})$ 仍为 Q 矩阵, 且 \bar{Q}^{-1} 存在, 则 (6.9.7) 式化为

$$\bar{F}_i(x) = \bar{q}_i \bar{q}_{i0} \bar{G}_i(x) + \bar{q}_I \sum_{j \in S} \bar{q}_{ij} \int_0^x \bar{F}_j(x-u) d\bar{G}(u) \quad (6.9.8)$$

由 (6.9.8) 式说明, 首达目标积分型泛函问题可化为首达时间问题. (要求 $r(i) > 0, i \in S$). 故下面只需讨论首达时间的问题.

设 $S = \{1, 2, \dots, p\}$ 有限, $S_0 = \{0\}$, 且 (6.9.1) 式总成立, 并设过程的初始分布为: $\alpha = \{\alpha_1, \dots, \alpha_p, 0\}$. $\alpha_i \geq 0, i \in S, \sum_{i \in S} \alpha_i = 1$. 记 $\Phi_i(s) = \int_0^\infty e^{-sx} dF_i(x)$, $\bar{\Phi}_i(s) = \int_0^\infty e^{-sx} d\bar{F}_i(x)$, $i \in S, x \geq 0, s \geq 0$. $\Phi(s) = \sum_{i=1}^m \alpha_i \Phi_i(s)$, $\bar{\Phi}(s) = \sum_{i=1}^m \alpha_i \bar{\Phi}_i(s)$. $F(x) = \{F_i(x), i \in S\}'$, $\Phi(s) = \{\Phi_i(s), i \in S\}'$.

定义 称从 S 到 S_0 的首达时间 τ 的分布 $F(x) = P(\tau \leq x)$ 为 Phase-Type 分布. 简记为 PH 分布. 称 $\Phi(s) = \int_0^\infty e^{-sx} dF(x), s \geq 0$ 为 PH 分布的生成函数, 即 $\Phi(s)$ 是 $F(x)$ 的 Laplace-Stieltjes 变换.

定理 6.9.3

$$\Phi(s) = (s + q_i)^{-1} q_{i0} + (s + q_i)^{-1} \sum_{j \in S} q_{ij} \Phi_j(s) \quad (6.9.9)$$

$$\Phi(s) = (sI - Q)^{-1} q_0, \quad s > 0 \quad (6.9.10)$$

证 对 (6.9.6) 式两边取 Laplace-Stieltjes 变换, 即得 (6.9.9) 式. 再注意到当 $s > 0$ 时, 矩阵 $(sI - Q)$ 是主对角严格占优矩阵, 故 $(sI - Q)^{-1}$ 存在. 从而 (6.9.9) 方程有唯一解. 即 (6.9.10) 式成立. \square

由 (6.9.10) 式可知 $F(x) = \{F_i(x), i \in S\}'$, $\Phi(s) = \{\Phi_i(s), i \in S\}'$ 完全由过程在 S 上的无穷小生成子 Q 唯一决定, 而 $\phi(s) = \alpha \Phi(s)$ 及 $F(x) = \alpha F(x)$ 由初始分布 α 及 Q 唯一决定. 因此, 可用 (α, Q) 表示 $F(x)$, 记为 $F(x) \sim (\alpha, Q)$, 称 (α, Q) 是 $F(x)$ 的一个表示.

对于首达时间的分布函数 $F(x)$ 、生成函数 $\Phi(s)$ 及矩 $\{J_k, k \geq 0\}$, 我们有以下

定理 6.9.4 $\Phi(s)$ 由其矩 $\{J_k, k \geq 0\}$ 唯一确定, 即存在 $s_0 > 0$, 使当 $|s| < s_0$ 时,

$$\Phi(s) = \sum_{k=0}^{\infty} \frac{(-1)^k}{k!} J_k s^k \quad (6.9.11)$$

证 证明从略.

令 $\mathbf{a}_k = \frac{(-1)^k}{k!} \mathbf{J}_k = \{a_k(l), l \in S\}^T$, 其中 $a_k(l) = (-1)^k \cdot J_k(l)/k!$, $\forall l \in S$ 则 $a_k = \alpha \mathbf{a}_k$, $\Phi(s) = \alpha \Phi(s)$, $k, k \geq 0$. 且

$$\Phi(s) = \sum_{n=0}^{\infty} a_n s^n \quad (6.9.12)$$

记 $B(k, r) = (\mathbf{a}_k, \mathbf{a}_{k+1}, \dots, \mathbf{a}_{k+r-1}), k \geq 0, r \geq 1$.

6.9 首达时间与首达目标积分型泛函的特性及其反问题

引理 6.9.5 $\text{rank} B(k, p) = \text{rank} B(0, p), \forall k \geq 0$.

证明. 因为 $\mathbf{a}_k = Q^{-k}\mathbf{e}$, $\text{rank} Q^{-1} = p$, 所以 $\forall k \geq 1$,

$$B(k, p) = (Q^{-k}\mathbf{e}, Q^{-(k+1)}\mathbf{e}, \dots, Q^{-(k+p-1)}\mathbf{e}) = Q^{-k+1}(Q^{-1}\mathbf{e}, Q^{-2}\mathbf{e}, \dots, Q^{-p}\mathbf{e}) = Q^{-k+1}B(1, p).$$

即 $\text{rank} B(k, p) = \text{rank} B(0, p)$.

定理 6.9.5 $1^\circ \forall k \geq 1$,

$$\mathbf{a}_k = Q^{-k}\mathbf{e} = Q^{-1}\mathbf{a}_{k-1}, \quad (6.9.13)$$

$$Q\mathbf{a}_k = \mathbf{a}_{k-1},$$

$2^\circ \forall k \geq 1$,

$$Q(\mathbf{a}_k, \mathbf{a}_{k+1}, \dots, \mathbf{a}_{k+p-1}) = (\mathbf{a}_{k-1}, \mathbf{a}_k, \dots, \mathbf{a}_{k+p-2}), \quad (6.9.14)$$

$$QB(k, p) = B(k-1, p), \quad (6.9.15)$$

3° 若 $\text{rank} B(1, p) = p$, 则

$$Q = B(0, p)B^{-1}(1, p) = B(k-1, p)B^{-1}(k, p), \quad (6.9.16)$$

$$\mathbf{q}_0 = -Q\mathbf{e} = -B(0, p)B^{-1}(1, p)\mathbf{e}, \quad (6.9.17)$$

且 $F(x) \sim (\alpha, B(0, p)B^{-1}(1, p))$, 即条件分布 $(F_i(x), i \in S)$ 由 τ 的前 p 阶条件矩唯一确定.

$\forall k \geq 1$,

$$\mathbf{a}_k = B(1, p)B^{-1}(0, p)\mathbf{a}_{k-1} = [B(1, p)B^{-1}(0, p)]^k \mathbf{e}, \quad (6.9.18)$$

4° 若 $\text{rank} B(1, p) = p$, 则 $\{\mathbf{a}_k, k \geq 0\}$ 由 $B(1, p)$, and $\{a_k, k \geq 0\}$ 唯一决定, 且是最小阶为 p 的差分序列.

证明. 由 (6.9.4) 式可得 1° 、 2° 和 3° 。 4° 可以由差分序列的性质得到.

以上结果说明, 当 $\det B(1, p) \neq 0$ 时, 可由 $B(1, p)$ 反求其无穷小生成元 Q . 这就是马氏链中的一类反问题.

当 $B(1, p)$ 不满秩时, 有以下定理:

定理 6.9.6 若 $\text{rank} B(1, p) = r, 1 \leq r \leq p$, 则经过重新排列可得 $\text{rank} B(1, r) = r$, 记 $S_{(1,2,\dots,r)} = \{1, 2, \dots, r\}, \tilde{S}_{(1,2,\dots,r)} = S_{(1,2,\dots,r)} \setminus \{1, 2, \dots, r\}$, 则

$$Q_{(1,2,\dots,r)} = B(0, r)B^{-1}(1, r), \quad (6.9.19)$$

是状态空间为 $\hat{S}_{(1,2,\dots,r)}$ 的马氏链的最小生成子, 且其条件生成函数为

$$F_l(x) \sim (\mathbf{e}_l, Q_{(1,2,\dots,r)}), l \in S_{(1,2,\dots,r)}. \quad (6.9.19a).$$

证明. 类似于定理 6.9.5 的证明.

由定理 6.9.6 可知, 若 $\text{rank} B(1, r) = r$, 我们就可以用状态空间 $\hat{S}_{(1,2,\dots,r)}$ 上的条件矩来计算 $Q_{(1,2,\dots,r)}$ 。但是 $Q_{(1,2,\dots,r)}$ 只能表示状态集 $\hat{S}_{(1,2,\dots,r)}$ 的性质, 对于其它状态的性质, 这个定理没能给出一个令人满意的答案。下面的两个定理就对 $B(1, p)$ 不满秩的情形做了补充, 首先给出两个不同状态集上最小生成子的关系。

以 $B_l(k, r)$ 记 $(a_k(l), a_{k+1}(l), \dots, a_{k+r-1}(l)), \forall l \in S$ 即 $B(k, r)$ 矩阵的第 l 行。

由 $\text{rank} B(1, p) = r$, 我们可以假定 $\text{rank} B(1, r) = r$, 则 (2.21) 式可写为

$$Q_{(1,2,\dots,r)} = \begin{pmatrix} B_1(0, r) \\ \vdots \\ B_r(0, r) \end{pmatrix} \begin{pmatrix} B_1(1, r) \\ \vdots \\ B_r(1, r) \end{pmatrix}^{-1}, \quad (6.9.20)$$

由于 $B(1, r)$ 的前 r 行是线性无关的, 其它 $p - r$ 行可以被前 r 行线性表示。因此有:

$$B_k(1, r) = \beta_k^1 B_1(1, r) + \dots + \beta_k^r B_r(1, r) = \sum_{l=1}^r \beta_k^l B_l(1, r), r+1 \leq k \leq p \quad (6.9.21)$$

由差分性可知, 对 $B(0, r)$ 同样有,

$$B_k(0, r) = \beta_k^1 B_1(0, r) + \dots + \beta_k^r B_r(0, r) = \sum_{l=1}^r \beta_k^l B_l(0, r), r+1 \leq k \leq p \quad (6.9.21a)$$

因为 $B_k(0, r)$ 的第一个元素为 1, 所以有 $\sum_{l=1}^r \beta_k^l = 1$ 。

对 $\forall k_1 \in S$, 我们都可以找到 $B(0, r)$ 的 $r-1$ 行使得这 r 行线性无关。这是因为一定存在 $i \in \{1, \dots, r\}$ 使得 $\beta_{k_1}^i \neq 0$, 不妨假定 $\beta_{k_1}^1 \neq 0$, 则 $B_{k_1}(1, r), B_2(1, r), \dots, B_r(1, r)$

线性无关。我们可以假定 $\text{rank} \begin{pmatrix} B_{k_1}(1, r) \\ \vdots \\ B_{k_r}(1, r) \end{pmatrix} = r$ 。

于是有:

定理 6.9.7 若 $\text{rank} \begin{pmatrix} B_{k_1}(1, r) \\ \vdots \\ B_{k_r}(1, r) \end{pmatrix} = r$, 状态空间 $\hat{S}_{(k_1, k_2, \dots, k_r)} = S_{(k_1, k_2, \dots, k_r)} \cup S_0$

上的最小生成子 $Q_{(k_1, k_2, \dots, k_r)}$ 满足

$$Q_{(k_1, k_2, \dots, k_r)} = \begin{pmatrix} \beta_{k_1}^1 & \dots & \beta_{k_1}^r \\ \vdots & \ddots & \vdots \\ \beta_{k_r}^1 & \dots & \beta_{k_r}^r \end{pmatrix} Q_{(1,2,\dots,r)} \begin{pmatrix} \beta_{k_1}^1 & \dots & \beta_{k_1}^r \\ \vdots & \ddots & \vdots \\ \beta_{k_r}^1 & \dots & \beta_{k_r}^r \end{pmatrix}^{-1}. \quad (6.9.22)$$

6.9 首达时间与首达目标积分型泛函的特性及其反问题

证明. 由于 $Q_{(k_1, k_2, \dots, k_r)} = \begin{pmatrix} B_{k_1}(0, r) \\ \vdots \\ B_{k_r}(0, r) \end{pmatrix} \begin{pmatrix} B_{k_1}(1, r) \\ \vdots \\ B_{k_r}(1, r) \end{pmatrix}^{-1}$, (6.9.23)

$$\begin{pmatrix} B_{k_1}(0, r) \\ \vdots \\ B_{k_r}(0, r) \end{pmatrix} = \begin{pmatrix} \beta_{k_1}^1 & \cdots & \beta_{k_1}^r \\ \vdots & \ddots & \vdots \\ \beta_{k_r}^1 & \cdots & \beta_{k_r}^r \end{pmatrix} \begin{pmatrix} B_1(0, r) \\ \vdots \\ B_r(0, r) \end{pmatrix}, \quad (6.9.24)$$

$$\begin{pmatrix} B_{k_1}(1, r) \\ \vdots \\ B_{k_r}(1, r) \end{pmatrix}^{-1} = \begin{pmatrix} B_1(1, r) \\ \vdots \\ B_r(1, r) \end{pmatrix} \begin{pmatrix} \beta_{k_1}^1 & \cdots & \beta_{k_1}^r \\ \vdots & \ddots & \vdots \\ \beta_{k_r}^1 & \cdots & \beta_{k_r}^r \end{pmatrix}^{-1}. \quad (6.9.25)$$

则 (6.9.22) 可以很容易得到。

再给出 $Q_{(1,2,\dots,r)}$ 与原来 PH 分布的最小生成子 Q 之间的关系。

定理 6.9.8 对任意给定的初始分布 $\tilde{\alpha} = (\alpha, 0) = (\alpha_1, \alpha_2, \dots, \alpha_p, 0)$, 做变换

$$(\gamma_1, \dots, \gamma_r) = (\alpha_1 + \sum_{k=r+1}^p \beta_k^1 \alpha_k, \dots, \alpha_r + \sum_{k=r+1}^p \beta_k^r \alpha_k),$$

把 $\tilde{\gamma} = (\gamma, 0)$ 当作新的拟初始分布, 就有 (α, Q) 和 $(\gamma, Q_{(1,2,\dots,r)})$ 表示的 PH- 分布相同。

证明. 由于 $(\gamma_1, \dots, \gamma_r) = (\alpha_1 + \sum_{k=r+1}^p \beta_k^1 \alpha_k, \dots, \alpha_r + \sum_{k=r+1}^p \beta_k^r \alpha_k)$, 及 $\sum_{l=1}^r \beta_k^l = 1$, 可以得到 $\sum_{k=1}^r \gamma_k = 1$, 把 $\tilde{\gamma}$ 看作一个新的拟初始分布。

$$(a_1, \dots, a_r) = (\alpha_1, \dots, \alpha_p) \begin{pmatrix} B_1(1, r) \\ \vdots \\ B_p(1, r) \end{pmatrix} = (\gamma_1, \dots, \gamma_r) \begin{pmatrix} B_1(1, r) \\ \vdots \\ B_r(1, r) \end{pmatrix}. \quad (6.9.26)$$

而 $\begin{pmatrix} B_1(1, r) \\ \vdots \\ B_r(1, r) \end{pmatrix}$ 即为以 $Q_{(1,2,\dots,r)}$ 为最小生成子的 PH 分布的条件矩阵, 所以由

(6.9.26) 式可知 (α, Q) 和 $(\gamma, Q_{(1,2,\dots,r)})$ 所表示的 PH 分布的前 r 阶矩相等。由于这两个 PH 分布的矩序列都是 r 阶的差分序列, 前 r 项相等则整个序列相等, 即这两个 PH 分布的各阶矩都相等。由定理 6.9.3 可知, PH 分布的有限阶矩可以决定分布函数和生成函数。所以它们表示的是同一个 PH 分布。(有兴趣的读者可以自己证明.)

这里研究条件矩向量, 避免了由初始分布 α 带来的复杂性。因为 q_{ij} 是转移率, 而首达时间的条件矩恰恰就描述了马氏链中各状态转移的性质, 所以我们可以从条件矩求得 Q 。另一方面, 如果我们用分布函数或是生成函数, 就把初始分布和 Q 的信息混杂在一起,

这样我们就会得到有至少 p^2 个未知数的 p 个非线性方程, 很难从中得到 Q 。前面的几个定理说明, 从条件矩的角度出发, 如果 $B(1, p)$ 满秩, 则 Q 被唯一决定, Q 和 Φ 可以被显式表出; 而当 $B(1, p)$ 不满秩时, 我们就可以找到一个更小的有限状态的模型来刻画整个马氏链。在要求条件分布向量相等的条件下, 可以构造一个新的 r 阶的 $Q_{(1, \dots, r)}$ 代替原来 p 阶的 Q , 再对初始分布进行变换, 使变换后的初始分布和 $Q_{(1, \dots, r)}$ 表示的就是原来的 PH 分布。可以说这在一定意义上把 PH 分布最小表示的问题推进了一大步。

以上结果有广泛的应用背景, 因为有时一个 $M.C\{X(t), t \geq 0\}$ 常常不知道转移矩阵 $\tilde{Q} = (q_{ij})$, 也不知道 $\Phi(s)$, $F(x)$, 但其首达时间是可测量的, 这样就可以应用以上结果求其 $\Phi(s)$ 及 $F(x)$, 甚至可构造一 M.C., 使其首达时间的概率特性为已给定的。

§ 6.10 状态分类

对于连续参数的马尔可夫链 $X = \{X(t), t \geq 0\}$, 任取 $h > 0$, 定义

$$X_n(h) = X_{nh}, \quad n \geq 0.$$

由马氏性知, $\{X_{nh}, n \geq 0\}$ 是一个离散时间的马尔可夫链, 称为以 h 为步长的 **离散骨架**, 或简称 **h 骨架**. h 骨架的转移概率矩阵即为 $P(h) = (P_{ij}(h))$, n 步转移概率矩阵则为 $P(nh)$. 离散时间马尔可夫链的许多性质与结果, 通过离散骨架必定在连续时间马氏链身上有所反映. 这也是我们利用已知结果讨论连续时间马氏链的一条有效途径.

与离散时间的马尔可夫链一样, 我们对连续时间的马尔可夫链也要讨论状态的分类, 转移概率函数的极限性质以及平稳分布. 有些概念, 例如两个状态的相通及在此基础上所做的状态分类等, 可以直接从离散时间情形搬到连续时间情形; 但也有些概念, 例如常返性及正常返性等, 却无法立即照搬过去. 为了使我们的讨论只需用初等的方法, 我们将通过对离散骨架的状态分类的讨论, 建立起连续时间马尔可夫链的状态分类. 这样做可以充分利用离散时间情形的已知结果.

定义 若存在 $t > 0$, 使 $P_{ij}(t) > 0$, 则称由状态 i 可达状态 j , 记为 $i \rightarrow j$. 若对一切 $t > 0$, $P_{ij}(t) = 0$, 则称由状态 i 不可达状态 j , 记为 $i \not\rightarrow j$. 若 $i \rightarrow j$ 且 $j \rightarrow i$, 则称状态 i 与 j 相通, 记为 $i \leftrightarrow j$.

由此定义知, 完全类似地, 可达与相通关系有传递性. 从而可以按相通关系给状态分类, 两两相通的状态组成一个状态类. 若整个状态空间是一个状态类, 则称该马氏链是不可约的.

上面这些定义与离散时间情形是完全相同的. 建立在可达与相通关系上的其它概念 (如闭集等) 和结果都可以搬过来使用, 继续有效, 我们不再重复叙述了.

定理 6.10.1 下列命题等价:

- (1) 由状态 i 可达状态 j ;
- (2) 对任意的 h 骨架, 由 i 可达 j ;
- (3) 对某一个 h 骨架, 由 i 可达 j (记为 $i \xrightarrow{h} j$).

证明 (2) \Rightarrow (3) \Rightarrow (1) 是显然的, 只要证 (1) \Rightarrow (2). 设 $t > 0$ 使 $P_{ij}(t) > 0$. 取 n 充分大使 $nh > t$, 则由 $C-K$ 方程知, $P_{ij}(nh) \geq P_{ij}(t)P_{jj}(nh-t)$ 又由定理 6.1.1 的证明知 $\forall t > 0$, 有 $P_{jj}(t) > 0$, 故

$$P_{ij}(nh) \geq P_{ij}(t)P_{jj}(nh-t) > 0$$

即 $i \xrightarrow{h} j$. 这对一切 $h > 0$ 成立. \square

在定理 6.10.1 中, 将可达改为相通显然也是成立的. 因此, 该定理说明, 从一个状态是否可达另一个状态, 两个状态是否相通, 对全部离散骨架和原来的连续时间马氏链都是一致的, 从而他们的状态类也都是一致的. 很自然的, 我们希望一个状态是常返的或非常返的, 正常返的或零常返的, 也应该对全部离散骨架都是一致的. 另一方面, 离散时间情形定义状态为常返的或非常返的, 正常返的或零常返的方法却不能直接搬到连续时间情形, 这也迫使我们试图从离散骨架的状态性质去寻找解决问题的途径. 这些考虑导致下面的结果.

定理 6.10.2 对任意的 $i \in S$, 若

$$\int_0^\infty P_{ii}(t)dt = \infty, \quad (6.10.1)$$

则对一切 $h > 0$,

$$\sum_n P_{ii}(nh) = \infty. \quad (6.10.2)$$

反之, 若对某一个 $h > 0$, (6.10.2) 式成立, 则 (6.10.1) 式成立.

证明 略, 可参见 [4].

由该定理可知, 一个状态是常返的或非常返的, 对全部的离散骨架来说是一致的. 这就自然的引出以下定义.

定义 对连续时间马氏链, 一个状态成为 **常返** 的或 **非常返** 的, 若对全部离散骨架这个状态是常返的或非常返的.

定理 6.10.2 也提供了常返的判别法: 状态 i 为常返的充要条件是

$$\int_0^\infty P_{ii}(t)dt = \infty.$$

为了进一步讨论正常返与零常返, 我们也要先讨论转移概率函数的极限性质. 在离散时间情形, 由于状态可能是周期的, 因而使情况复杂化了. 但在连续时间情形, 由于对一切 $h > 0$ 及正整数 n , 对一切 $i \in S, P_{ii}(nh) > 0$, 对任意离散骨架, 每个状态都是非周期的. 所以, 周期的概念对连续时间马氏链就不需要了, 由周期性造成的麻烦也就没有了.

定理 6.10.3 对一切 $i, j \in S$, 存在极限

$$\lim_{t \rightarrow \infty} P_{ij}(t) = \pi_{ij}.$$

证明 略, 可参见 [4].

由该定理可知, 对一切 $h > 0$ 极限

$$\lim_{n \rightarrow \infty} P_{ii}(nh) = \pi_{ii} = \pi_i,$$

与 h 无关, 因此一个常返状态 i 为正常返的 ($\pi_i > 0$) 或零常返的 ($\pi_i = 0$) 对全部离散骨架来说也是一致的. 类似的给出下面的定义.

定义 对连续时间马氏链, 一个常返状态称为 **正常返** 的或 **零常返** 的, 若对全部离散骨架这个状态是正常返的或零常返的.

状态 i 为正常返的充要条件是 $\pi_i > 0$.

练习题

6.1 设 $\{N(t), t \geq 0\}$ 是参数为 λ 的 Poisson 过程, 过程 $\{X(t), t \geq 0\}$ 定义为 $\{X(t) = 1\} = \bigcup_{n=0}^{\infty} (N(t) = 2n)$, $\{X(t) = 0\} = \bigcup_{n=0}^{\infty} (N(t) = 2n+1)$, 试证 $\{X(t), t \geq 0\}$ 为 MC, 并求 $P(t)$ 与 $Q = (q_{ij})$.

6.2 设 $\{X(t), t \geq 0\}$ 为 MC, $S = \{0, 1\}$, $Q = \begin{pmatrix} -\lambda & \lambda \\ \mu & -\mu \end{pmatrix}$, $P_0(0) = 1$.
 $\tau_1 = \inf\{t : t > 0, X(t) \neq X(0)\}$

求 $E(X(t))$, $E(\tau_1 | X(0) = 0)$, $cov(X(s), X(t))$, $E\{X(s+t) | X(s) = 1\}$.

6.3 设 $\{N(t), t \geq 0\}$ 是参数为 λ 的 Poisson 过程, 且设每次到达被登记上的概率为 p , 并与其它到达独立. 记 $\{N_p(t), t > 0\}$ 为登记到达的过程. 证 $\{N_p(t), t \geq 0\}$ 是参数为 $p\lambda$ 的 Poisson 流.

6.4 设 $\{N_i(t), t \geq 0\}$ 是参数为 λ_i 的 Poisson 过程且相互独立 ($i=1, 2$). $X(t) = N_1(t) - N_2(t)$, $P_n(t) = P(X(t) = n)$, $n \in Z = \{0, \pm 1, \pm 2, \dots\}$, $T_i = \inf\{t : t > 0, N_i(t) = k\}$, 试证

$$\sum_{n=-\infty}^{\infty} P_n(t) z^n = e^{-(\lambda_1 + \lambda_2)t} \cdot e^{(\lambda_1 z + \lambda_2/z)t}$$

并求 $E[X(t)]$, $E(X(t)^2)$ 及 $P(T_1 < T_2 | N(0) = N_2(0) = 0)$.

6.5 下列三个生灭过程的参数分别为

232

1° $\lambda_n = \lambda q^n$, $0 < q < 1$, $\lambda > 0$, $n \geq 0$, $\mu_n = \mu$, $n > 1$, $\mu_0 = 0$;

2° $\lambda_n = \lambda(n+1)^{-1}$, $\lambda > 0 (n \geq 0)$, $\mu_n = \mu$, $(n \geq 1)$, $\mu_0 = 0$;

练习题

3 ° 有迁入的线性增长模型: $\lambda_n = n\lambda + a$, $\mu_n = n\mu$, $\lambda > 0$, $\mu > 0$, $a > 0$
(不妨设 $\frac{(\lambda+a)}{\mu} < 1$)

试求相应的平稳分布。

6.6 设 $\{X(t), t \geq 0\}$ 是纯生 yule 过程 $\{\lambda_n = n\lambda, \mu_n = 0, \lambda > 0\}$, 证

$$P(X(t) \geq n | X(0) = N) = \sum_{k=n-N}^{n-1} \binom{n-1}{k} p^k q^{n-1-k}, n > N.$$

$$q = 1 - p = e^{-\lambda t},$$

并证

$$E[X(t)] = e^{\lambda t}, \quad Var X(t) = e^{2\lambda t}(1 - e^{-\lambda t}).$$

6.7 设 $\{X(t), t \geq 0\}$ 为纯灭过程 $(\lambda_n = 0, \mu_n = n\mu, \mu > 0, n \geq 1)$, 设 $X(0) = i$, 求

$$P_n(t) = P(X(t) = n), \quad E[X(t)], \quad Var[X(t)].$$

$$\{P_n(t) = \binom{i}{n} e^{-n\mu t} (1 - e^{-\mu t})^{(i-n)}, \quad E[X(t)] = ie^{-\mu t},$$

$$Var[X(t)] = ie^{-\mu t}(1 - e^{-\mu t})\}.$$

6.8 设 $\{X_i(t), t \geq 0\} (i = 1, 2)$ 是二个互相独立、有相同参数 λ 的 yule 过程, $X_i(0) = n_i$, $N \geq n_1 + n_2$, 给定 $X_1(t) + X_2(t) = N$, 试求 $X_1(t)$ 的条件分布律。

6.9 考虑 M/M/s 排队系统, 顾客按照参数为 λ 的 Poisson 流到达一个有 s 个服务员的服务站。每个顾客一到来, 如果有服务员空闲, 则直接进入服务, 否则加入排队行列等待。当一个服务员结束对一位顾客服务时, 顾客即离开系统, 排队中的下一顾客立即被服务 (若有顾客等待)。假定相继的服务时间是相互独立, 且参数为 μ 的指数分布的随机变量, 如果以 $X(t)$ 表时刻 t 系统的顾客数, 则 $\{X(t), t \geq 0\}$ 是生灭过程。

$$\mu_n = \begin{cases} n\mu & 1 \leq n \leq s \\ s\mu & n > s \end{cases}, \lambda_n = \lambda, n \geq 0.$$

设 $\rho = \frac{\lambda}{\mu s} < 1$, $Q(t) = \max(X(t) - s, 0)$ 是 t 时等待的顾客数。

1 ° 求系统的平稳分布;

2 ° 证明在稳态下

$$r = P(Q(t) = 0)$$

$$= \left(\sum_{i=0}^s (s\rho)^i / i! \right) \left\{ \sum_{i=0}^s (\rho s)^i / i! + [(s\rho)^s \rho / (s!(1-\rho))] \right\}$$

$$E[Q(t)] = (1-r)(1-\rho)^{-1}.$$

233

6.10 一家由一个理发员营业的小理发店, 至多能容纳两个顾客, 顾客到达是速率为每小时 3 人的 Poisson 流, 相继服务时间是均值为 $\frac{1}{4}$ 小时的指数随机变量。求

1° 店中顾客的平均数是多少?

2° 进店的顾客比例;

3° 若理发员能加快一倍地工作, 他会多做多少生意?

6.11 若 $\{X_i(t), t \geq 0\} (i = 1, 2)$ 是两个相互独立的可逆马氏链, 证明 $\{X_1(t), X_2(t), t \geq 0\}$ 也是可逆链。

6.12 考虑参数分别为 λ_i, μ_i 的两个 M/M/1 排队系统, 其中 $\lambda_i < \mu_i (i = 1, 2)$ 。假设它们共同使用一个容纳 n 个人的候客室 (即每当候客室占满时如再来客都自行离去消失), 计算在第一个系统中有 k 人 (当 $k > 0$ 时 1 人在接受服务而 $k-1$ 在候客室等待) 而 l 人在第二个系统的极限概率 (提示: 利用 6.11 习题的结果)。

6.13 考虑一个 M/M/ ∞ 排队系统, 具有编号为 1, 2, ... 的通道 (服务员) 顾客一来就挑选编号为最小的通道接受服务。于是我们可以认为一切来到全部发生在 1 号通道, 当发现 1 号通道忙着的顾客就溢出而变成 2 号通道, 当发现 1 号与 2 号通道都忙着的顾客就溢出变成 3 号通道, ... 等等。在稳态下

1° 1 号通道忙时占多少比例?

2° 通过考虑相应的 M/M/2 消失系统, 确定 2 号通道忙时的比例。

3° 对任意第 C 号通道忙时比例是多少?

4° 从 C 号通道到 $C+1$ 号通道的溢出率是多少? 相应的溢出过程是 Poisson 流? 并加以解释。

6.14 一排队系统在任一时刻的工作量定义为该时刻系统中全体顾客的剩余服务时间之和, 试求稳态时的 M/G/1 排队系统工作量的期望值与方差。

6.15 设 $X = \{X(t), t \geq 0\}$ 为稳态下的遍历马氏链, $Q = (q_{ij}), (P_j, j \geq 0)$ 为平稳分布, 把状态空间 S 分为二个子集 $S = B \cup B^c$, $B^c = G$, $\forall i \in B$

$$T_i = \inf\{t : t > 0, X(0) = i, X(t) \in G\}$$

记

$$\tilde{F}_i(s) = E\{e^{-sT_i} | X(0) = i\}, \quad P_{ij} = q_{ij} / \sum_{j \neq i} q_{ij}$$

$$T_v = \inf\{s : s > 0, X(t) \in G, X(t) \in B, X(t+s) \notin B\},$$

$$T_v = \inf\{s : s > 0, X(t) \in B, X(t+s) \notin B\}.$$

1° 求 $P\{X(t) = i | X(t) \in B\}, i \in B$ 。

2° 求 $P\{X(t) = i | X(t) \in B, X(t^-) \in G\}$ 。

3° 证

$$\tilde{F}_i(s) = q_i(q_i + s)^{-1} \left[\sum_{j \in B} \tilde{F}_j(s) P_{ij} + \sum_{j \in G} P_{ij} \right].$$

4°

234

$$\sum_{j \in G} \sum_{j \in B} P_{ij} q_{ij} = \sum_{i \in B} \sum_{j \in G} P_{ij} q_{ij}.$$

练习题

5° 利用 3° 及 4°，证

$$s \sum_{i \in B} P_i \tilde{F}_i(s) = \sum_{i \in G} \sum_{j \in B} P_i q_{ij} (1 - \tilde{F}_j(s)).$$

6° 利用 2° 试推导

$$E[e^{-sT_v} | X(t^-) \in G, X(t) \in B] = \left(\sum_{i \in B} \sum_{j \in G} \tilde{F}_i(s) P_j q_{ji} \right) \left[\sum_{j \in G} \sum_{k \in B} P_j q_{jk} \right]^{-1}.$$

7° 利用 5° 及 6°，证

$$\sum_{j \in B} P_j = \left[\sum_{i \in G} \sum_{j \in B} P_i q_{ij} \right] E\{T_v | X(t^-) \in G, X(t) \in B\}.$$

8° 利用 1°、5°、6° 及 7°，证

$$E\{e^{-sT_v} | X(t) \in B\} = [1 - E(e^{-sT_v} | X(t^-) \in G, X(t) \in B)] \cdot \{sE[T_v | X(t) \in G, X(t) \in B]\}^{-1}$$

9° 利用 8° 与 Laplace 变换的唯一性，证

$$P\{T_x \leq s | X(t) \in B\} = \left[\int_t^{t+s} P\{T_v > u | X(t^-) \in G, X(t) \in G\} du \right] \cdot \{E[T_v | X(t^-) \in G, X(t) \in B]\}^{-1}.$$

10° 利用 9° 证

$$\begin{aligned} & E\{T_x | X(t) \in B\} \\ &= E[T_v^2 | X(t^-) \in G, X(t) \in B][2E(T_v | X(t^-) \in G, X(t) \in B)]^{-1} \\ &\geq \frac{1}{2} E[T_v | X(t^-) \in G, X(t) \in B]. \end{aligned}$$

6.16 设 $\{X(t), t \geq 0\}$ 是纯生过程， $\lambda_n = n\lambda + \delta, n \geq 0, \lambda, \delta > 0$ ，求其 $P(t) = (P_{ij}(t))$ 。

6.17 设 $\{X(t), t \geq 0\}$ 是生灭过程， $\lambda_n = n\lambda + \delta, n \geq 0, \lambda, \delta > 0, \mu_0 = n\mu, n \geq 1, \mu > 0$ ，

证

1° $\lambda > \mu$ 或 $\lambda = \mu < \delta$ 时，链为非常返的；

2° $\lambda = \mu \geq \delta$ 时，链为零常返的；

3° $\lambda < \mu$ 时，链为正常返的，且这是平稳分布为

$$\pi_0 = (1 - \frac{\lambda}{\mu})^{\frac{\delta}{\lambda}}, \quad \pi_n = \frac{1}{n!} \frac{\delta}{\lambda} (\frac{\delta}{\lambda} + 1) \cdots (\frac{\delta}{\lambda} + n - 1) (\frac{\lambda}{\mu}) (1 - \frac{\lambda}{\mu})^{\delta/\lambda}, n \geq 1.$$

235

6.18 一个汽车加油站只能给一辆汽车加油，加油时间服从参数为 μ 的指数分布，各辆汽车的加油时间相互独立，加油的汽车按参数为 λ 的 Poisson 过程到达，当一辆汽车

来到加油站发现站中已有 n 辆汽车时, 以概率 $\frac{n}{n+1}$ 立即离去, 以概率 $\frac{1}{n+1}$ 留下来排队, 记 $X(t)$ 为时刻 t 加油站中汽车的数目, 证 $\{X(t), t \geq 0\}$ 为正常返不可约链并求其平稳分布。

6.19 一个系统由 n 个不同的部件串联构成, n 个部件的寿命分别服从参数为 λ_i 的指数分布, 失效后的修理时间分别服从参数为 μ_i 的指数分布, 若 n 个部件都正常工作, 则系统处于工作状态; 若有某个部件失效, 则系统失效, 这时修理工立即对失效部件进行处理, 其余部件停止工作, 若失效部件修复, 所有部件立即进入工作状态, 从而系统处于工作状态。假设各部件的失效与否相互独立, 求系统处于工作状态的概率。

6.20 设 M.C. $\{X(t), t \geq 0\}$, $S = \{0, 1, 2\}$, $\pi(0) = (0, \alpha_1, \alpha_2)$, $\alpha_i \geq 0$, $\sum_{i=1}^2 \alpha_i = 1$,

$$Q = \begin{pmatrix} 0 & 0 & 0 \\ 1 & -4 & 3 \\ 1 & 2 & -3 \end{pmatrix}$$

$T = \inf\{t : t \geq 0, X(t) = 0\}$, 求:

- 1° τ_2 的分布及 $E\tau_2$;
- 2° T 的分布及 ET 。

第七章 随机微分方程

§ 7.1 H 空间和均方收敛

在许多情况下,人们关心的是一个过程的一阶矩、二阶矩特征,这是比较容易得到的随机变量的“外部”数字特征.因此,研究二阶矩存在的随机变量是一个重要的方向,通过深入分析,探知这类随机变量有哪些共同的性质.

首先,我们给出复随机变量的定义.设 (X, Y) 为实随机变量,称 $Z = X + iY$ 为复随机变量.其中 $i = \sqrt{-1}$, $|Z|^2 \triangleq Z\bar{Z} = (X + iY)(\bar{X} + i\bar{Y}) = X^2 + Y^2$.

对于复 r.v. Z , 有

$$EZ \triangleq EX + iEY$$

$$E|Z|^2 \triangleq E(Z\bar{Z})$$

为了对存在二阶矩的随机变量的全体进行统一考察,我们引出 H 空间的概念.为研究这一类随机变量提供数学框架与几何直观解释.

定义 $H \triangleq \{X : E|X|^2 < \infty\}$, 即 H 是由二阶矩存在的随机变量全体构成的集合,称作 H 空间. □

H 空间具有以下良好性质:

H 空间是线性空间,即: $\forall X_1, X_2 \in H$, 及常数 $\alpha_i \in R, (i = 1, 2)$, 都有 $\alpha_1 X_1 + \alpha_2 X_2 \in H$ 成立.这是因为:

$$E|\alpha_1 X_1 + \alpha_2 X_2|^2 \leq |\alpha_1|^2 E|X_1|^2 + |\alpha_2|^2 E|X_2|^2 + 2|\alpha_1 \alpha_2| E|X_1 X_2|$$

而由 Schwartz 不等式 $E|X_1 X_2| \leq (E|X_1|^2 \cdot E|X_2|^2)^{\frac{1}{2}}$, 因 $X_1, X_2 \in H$, 则 $E|X_1|^2 < \infty, E|X_2|^2 < \infty$, 所以 $E|\alpha_1 X_1 + \alpha_2 X_2|^2 < \infty$, 即 $\alpha_1 X_1 + \alpha_2 X_2 \in H$. □

在几何中我们所熟悉的 n 维欧几里得空间是线性空间,在该空间中引进了内积,范数,距离与极限等概念.受此启发,若能在 H 空间中引入类似的量,那么这些量就可以赋予它们相应的几何意义,从而可借用几何的观点与方法来刻划和研究 H 空间的性质.

不失一般性,以下设 $EX = EY = 0$.

$\forall X, Y \in H$, 定义 $(X, Y) = E(X\bar{Y})$. 由定义,易知 (X, Y) 满足以下性质:

1° $(Y, X) = \overline{(X, Y)}$ (即 (X, Y) 共轭反对称)

2° $(cX, Y) = c(X, Y)$ 其中 c 为常数

3° $(X_1 + X_2, Y) = (X_1, Y) + (X_2, Y)$ 其中 $X_i \in H, (i = 1, 2)$

4° $(X, X) = E|X|^2 \geq 0$, 且 $(X, X) = 0 \Leftrightarrow X = 0$ (a.e.)

我们称 (X, Y) 为 H 空间中 X, Y 的 **内积**.

7.1 H 空间和均方收敛

若 $(X, Y) = 0$ (因为 $EX = EY = 0$, 所以 $Cov(X, Y) = 0$, 即 X, Y 不相关), 称 X 与 Y **正交**, 记作 $X \perp Y$. 这样, 对两个 *r.v.* X, Y 不相关 $\Leftrightarrow X \perp Y$, 赋予了几何上的直观意义.

对 $\forall X \in H$, 记 $\|X\| = (X, X)^{\frac{1}{2}}$, 即 $\|X\| = (E|X|^2)^{\frac{1}{2}}$. 显然 H 空间中 $\|\cdot\|$ 满足:

1° $\|X\| \geq 0$, 且 $\|X\| = 0 \Leftrightarrow X = 0(a.e.)$

2° $\|cX\| = |c| \cdot \|X\|$, 其中 c 为常数

3° $\|X_1 + X_2\| \leq \|X_1\| + \|X_2\|$ (三角不等式), 其中 $X_i \in H, (i = 1, 2)$

称 $\|X\|$ 为 H 中 X 的 **范数**. 易证:

$$|EX| \leq E|X| \leq \|X\| \quad (7.1.1)$$

证 由 Jenson 不等式, 对凸函数 $g(x)$, 有 $g(EX) \leq E(g(x))$.

取 $g(x) = |x|$, 则有 $|EX| \leq E|X|$.

由 Schwartz 不等式, $(E|X|)^2 \leq E|X|^2 \cdot 1^2 \Rightarrow E|X| \leq \|X\|$.

所以 $|EX| \leq E|X| \leq \|X\|$ □

记 $d(X, Y) = \|X - Y\|$, 显然:

1° $d(X, Y) \geq 0$, 且 $d(X, Y) = 0 \Leftrightarrow X = Y (a.e.)$

2° $d(X, Y) = d(Y, X)$

3° $d(X, Z) \leq d(X, Y) + d(Y, Z)$

称 $d(X, Y)$ 为 H 中 X 与 Y 之间的 **距离**.

这样, 在 H 空间中定义了二元素的内积、距离和一元素的范数, 它们与 n 维欧几里德空间中二元素 (向量) 的内积、距离和一元素的范数相类似. 并且, 在此基础上, 可以在 H 空间中定义极限和收敛的概念:

定义 设 $\{X, X_n, n \geq 1\} \subset H$

1° 若 $\lim_{n \rightarrow \infty} d(X_n, X) = 0$, 即 $\lim_{n \rightarrow \infty} \|X_n - X\| = \lim_{n \rightarrow \infty} (E|X_n - X|^2)^{\frac{1}{2}} = 0$, 则称 X 为序列 $\{X_n, n \geq 1\}$ 的 **均方极限**, 记作

$$\lim_{n \rightarrow \infty} X_n \stackrel{m.s.}{=} X \quad (m.s.: \text{mean square})$$

简记 $\lim_{n \rightarrow \infty} X_n = X$, 或 $X_n \stackrel{m.s.}{\Rightarrow} X (n \rightarrow \infty)$,

即, 序列 $\{X_n, n \geq 1\}$ **均方收敛** 于 X .

2° 若 $\lim_{n \rightarrow \infty, m \rightarrow \infty} d(X_n, X_m) = 0$, 则称 $\{X_n, n \geq 1\}$ 是 **柯西序列** (Cauchy 序列).

例 对于 B.M. $\{B(t), t \geq 0\}$, $B(0) = 0, \forall 0 = t_0 < t_1 < t_2 \cdots < t_n = t, \Delta t_k = t_k - t_{k-1} (1 \leq k \leq n)$, 令 $\delta = \max_{1 \leq k \leq n} \Delta t_k, \Delta B_k = B(t_k) - B(t_{k-1})$, 则

$$\begin{aligned} 0 \leq \lim_{\delta \rightarrow 0} [E(\sum_{k=1}^n \Delta^2 B_k - t)^2] &= \lim_{\delta \rightarrow 0} [E(\sum_{k=1}^n (\Delta^2 B_k - \Delta t_k)^2)] \\ &= \lim_{\delta \rightarrow 0} \{ \sum_{k=1}^n [E(\Delta^2 B_k) - \Delta t_k]^2 \} + 0 \end{aligned}$$

$$= \lim_{\delta \rightarrow 0} 2 \left(\sum_{k=1}^n \Delta^2 t_k \right) \leq 0$$

故

$$\lim_{\delta \rightarrow 0} \sum_{k=1}^n \Delta^2 B_k \stackrel{m.s.}{=} t.$$

□

命题 7.1.1 设 $(X_n, n \geq 1)$ 为 H 空间中的 Cauchy 序列, 则必存在 r.v. $X \in H$, 使得

$$X_n \stackrel{m.s.}{\rightarrow} X$$

(此命题证明要用到测度论, 此处从略)

注: 这说明 H 空间是一个完备的赋范线性空间.

命题 7.1.1 给出了均方极限存在的一个充分条件.

均方极限具有与一般极限相类似的运算规则:

命题 7.1.2 设 $X_n, X, Y_n, Y \in H$, 且 $X_n \stackrel{m.s.}{\rightarrow} X, Y_n \stackrel{m.s.}{\rightarrow} Y$, 则

$$1^\circ \lim_{n \rightarrow \infty} EX_n = EX = E \lim_{n \rightarrow \infty} X_n, \lim_{n \rightarrow \infty} E|X_n|^2 = E|X|^2$$

$$2^\circ \lim_{m \rightarrow \infty, n \rightarrow \infty} (X_m, Y_n) = (X, Y)$$

$$3^\circ \lim_{n \rightarrow \infty} (\alpha X_n + \beta Y_n) = \alpha X + \beta Y, \forall \alpha, \beta \in R.$$

证 1° 因 $|EX_n - EX| \leq E|X_n - X| \leq \|X_n - X\|$, 则 $\lim_{n \rightarrow \infty} |EX_n - EX| = 0$, 所以 $\lim_{n \rightarrow \infty} EX_n = EX$.

同理, 由 $||X_n| - |X|| \leq \|X_n - X\|$ 可得 $\lim_{n \rightarrow \infty} E|X_n|^2 = E|X|^2$.

2° 因

$$\begin{aligned} |(X_m, Y_n) - (X, Y)| &= |(X, Y_n - Y) + (X_m - X, Y) + (X_m - X, Y_n - Y)| \\ &\leq |(X, Y_n - Y)| + |(X_m - X, Y)| + |(X_m - X, Y_n - Y)| \\ &\leq \|X\| \cdot \|Y_n - Y\| + \|X_m - X\| \cdot \|Y\| + \|X_m - X\| \cdot \|Y_n - Y\| \end{aligned}$$

当 $n \rightarrow \infty$ 时, $\|Y_n - Y\| \rightarrow 0$, 当 $m \rightarrow \infty$ 时, $\|X_m - X\| \rightarrow 0$,

所以 $\lim_{n \rightarrow \infty, m \rightarrow \infty} |(X_m, Y_n) - (X, Y)| = 0$, 即 $\lim_{m \rightarrow \infty, n \rightarrow \infty} (X_m, Y_n) = (X, Y)$.

3° 显然. □

命题 7.1.3 $\lim_{n \rightarrow \infty} X_n = X$ 的充要条件是: $\lim_{n \rightarrow \infty, m \rightarrow \infty} (X_m, X_n) = C$ 存在, 且此时 $\lim_{n \rightarrow \infty, m \rightarrow \infty} (X_m, X_n) = E|X|^2 = \|X\|^2$.

证 必要性由命题 7.1.2 的 2° 可得, 下面证明充分性.

设 $\lim_{n \rightarrow \infty, m \rightarrow \infty} (X_m, X_n) = C$. 先证 $\{X_n, n \geq 1\}$ 是柯西序列.

$$\begin{aligned} \|X_m - X_n\|^2 &= (X_m - X_n, X_m - X_n) \\ &= (X_m, X_m) - (X_m, X_n) - (X_n, X_m) + (X_n, X_n) \xrightarrow{n \rightarrow \infty, m \rightarrow \infty} 0 \end{aligned}$$

7.2 均方分析

所以 $\{X_n, n \geq 1\}$ 是柯西序列. 由命题 7.1.1 知, $\exists X \in H$, 有 $\lim_{n \rightarrow \infty} X_n = X$. \square

命题 7.1.4 若 $\lim_{n \rightarrow \infty} X_n \stackrel{m.s.}{=} X$, 则

$$1^\circ \lim_{n \rightarrow \infty} X_n \stackrel{P}{=} X$$

2 $^\circ$ $\lim_{n \rightarrow \infty} P(X_n \leq x) = P(X \leq x)$ 成立, 其中 $x \in R$ 是 $P(X \leq x)$ 的连续点, (即 $X_n \xrightarrow{d} X(n \rightarrow \infty)$)

证 1 $^\circ$ 由 Chebyshev 不等式得, $\forall \varepsilon > 0, 0 \leq P(|X_n - X| \geq \varepsilon) \leq \frac{E|X_n - X|^2}{\varepsilon^2} \rightarrow 0$, 故 $\forall \varepsilon > 0, \lim_{n \rightarrow \infty} P(|X_n - X| < \varepsilon) = 1$, 即 $\lim_{n \rightarrow \infty} X_n \stackrel{P}{=} X$.

2 $^\circ$ 由 1 $^\circ$ 知, 只需证明: 若 $\lim_{n \rightarrow \infty} X_n \stackrel{P}{=} X$, 则有 $X_n \xrightarrow{d} X(n \rightarrow \infty)$.

设 $F_n(x) = P(X_n \leq x)$, $F(x) = P(X \leq x)$, 设 x 是 $F(x)$ 的连续点, 取 $\forall y < x$, 则

$$\begin{aligned} (X \leq y) &= (X \leq y, X_n \leq x) \cup (X \leq y, X_n > x) \\ &\subset (X_n \leq x) \cup (|X_n - X| > x - y) \\ &\Rightarrow F(y) \leq F_n(x) + P(|X_n - X| \geq x - y) \quad \forall n \geq 1 \end{aligned}$$

当 $n \rightarrow \infty$, 取下极限, 由概率收敛, $F(y) \leq \underline{\lim}_{n \rightarrow \infty} F_n(x) + 0$. (因为正实数序列的下极限总存在, 所以 $\underline{\lim}_{n \rightarrow \infty} F_n(x)$ 存在).

同理取 $\forall z > x$, 则

$$\begin{aligned} (X_n \leq x) &= (X_n \leq x, X \leq z) \cup (X_n \leq x, X > z) \\ &\subset (X \leq z) \cup (|X - X_n| > z - x) \\ &\Rightarrow F_n(x) \leq F(z) + P(|X_n - X| \geq z - x) \quad \forall n \geq 1 \end{aligned}$$

当 $n \rightarrow \infty$, 取上极限, $\overline{\lim}_{n \rightarrow \infty} F_n(x) \leq F(z)$.

则 $\forall y < x < z, F(y) \leq \underline{\lim}_{n \rightarrow \infty} F_n(x) \leq \overline{\lim}_{n \rightarrow \infty} F_n(x) \leq F(z)$.

令 $y \uparrow x, z \downarrow x$, 有

$$\lim_{y \uparrow x} F(y) = F(x) \quad \lim_{z \downarrow x} F(z) = F(x)$$

所以 $\lim_{n \rightarrow \infty} F_n(x) = \underline{\lim}_{n \rightarrow \infty} F_n(x) = \overline{\lim}_{n \rightarrow \infty} F_n(x) = F(x)$. \square

§ 7.2 均方分析

在引出均方极限之后, 我们就可以对过程的均方分析特性展开深入的讨论. 类似于数学分析中的概念, 本节介绍均方分析 (随机微积分), 即均方连续性, 均方可导, 均方积分.

240

设 $\{X(t), t \geq 0\}$ 为一随机过程, 若 $\forall t \geq 0, X(t) \in H$, 则称 $\{X(t), t \geq 0\}$ 为二阶矩过程.

1° 均方连续性

定义 设对二阶矩过程 $\{X(t), t \in T\}$, 若对 $\forall t_0 \geq 0$ 有 $\lim_{t \rightarrow t_0} X(t) \stackrel{m.s.}{=} X(t_0)$, 即 $\lim_{t \rightarrow t_0} \|X(t) - X(t_0)\| = 0$, 则称 $X(t)$ 在 t_0 均方连续.

若 $X(t)$ 对 $\forall t \in T$ 都均方连续, 则称 $\{X(t), t \in T\}$ 在 T 上均方连续.

例 设 $\{N(t), t \geq 0\}$ Poisson 过程, 可以证明 $N(t)$ 在 $t \geq 0$ 上均方连续. 由关系式 $E(N(t+h) - N(t))^2 = (\lambda h)^2 + \lambda h$ 即可立刻得到.

又例如 $B.M.\{B(t), t \geq 0\}$, 因为 $E(B(t+h) - B(t))^2 = |h| \rightarrow 0$, (当 $h \rightarrow 0$), 所以 $\lim_{t \rightarrow t_0} B(t) \stackrel{m.s.}{=} B(t_0)$, 即 $B(t)$ 在 $t \geq 0$ 上均方连续.

为了判别 $X(t)$ 的均方连续性, 除了利用定义, 还可以利用以下定理:

定理 7.2.1 记 $R(s, t) = E(X(s) \cdot \overline{X(t)}) = (X(s), X(t))$, 则 $\{X(t), t \geq 0\}$ 在 t_0 点均方连续的充要条件是 $R(s, t)$ 在 (t_0, t_0) 点连续.

证 由命题 7.1.3 即可得.

推论 1 $\{X(t), t \in T\}$ 在 T 上均方连续的充要条件是 $R(s, t)$ 在 $\{(t, t), t \in T\}$ 上二元连续.

推论 2 若 $R(s, t)$ 在 $\{(t, t), t \in T\}$ 上连续, 则它在 $T \times T$ 上连续.

即对协方差 $R(s, t)$ 而言, 它在整个区域 $T \times T$ 上连续与它在 $T \times T$ 的对角线上连续是等价的.

证 必要性显然, 只证充分性.

由定理 7.2.1, $R(s, t)$ 在 $(t, t), t \in T$ 连续 $\Leftrightarrow \forall s_0 \in T, \lim_{s \rightarrow s_0} X(s) = X(s_0)$. 由命题 7.1.3, 有 $\lim_{s \rightarrow s_0, t \rightarrow t_0} (X(s), X(t)) = (X(s_0), X(t_0)) = R(s_0, t_0)$. 即 $R(s, t)$ 在 $T \times T$ 上连续.

2° 均方可导(微)

定义 称二阶矩过程 $\{X(t), t \in T\}$ 在 $t_0 \in T$ 点上均方可导, 若

$$\lim_{h \rightarrow 0} \frac{X(t_0 + h) - X(t_0)}{h} \stackrel{m.s.}{=} X'(t_0)$$

存在. 此时称 $X'(t_0) = \left. \frac{dX(t)}{dt} \right|_{t_0}$ 与 $X'(t_0)dt$ 分别为 $X(t)$ 在 t_0 点的均方导数与均方微分.

若 $X(t), \forall t \in T$ 均方可导, 则称 $\{X(t), t \in T\}$ 在 T 上是均方可导的. 此时记

$$\lim_{h \rightarrow 0} \frac{X(t+h) - X(t)}{h} = X'(t)$$

($\frac{dX(t)}{dt}$ 或 $\dot{X}(t)$) 与 $X'(t)dt$ 分别称为 $X(t)$ 在 T 上的均方导数与均方微分.

下面给出均方可导的判定定理.

定理 7.2.2(均方可导准则) $\{X(t), t \in T\}$ 在 t 点均方可导的充要条件是

$$\lim_{h \rightarrow 0, l \rightarrow 0} \frac{R(t+h, t+l) - R(t+h, t) - R(t, t+l) + R(t, t)}{h \cdot l} \text{ 存在.}$$

即要求 $R(s, t)$ 在 (t, t) 上广义二次可微.

7.2 均方分析

证 由

$$\frac{R(t+h, t+l) - R(t+h, t) - R(t, t+l) + R(t, t)}{h \cdot l} = \left(\frac{X(t+h) - X(t)}{h}, \frac{X(t+l) - X(t)}{l} \right)$$

和命题 7.1.3 可得

$$\lim_{h \rightarrow 0} \frac{X(t+h) - X(t)}{h} \text{ 存在} \Leftrightarrow \lim_{h \rightarrow 0, l \rightarrow 0} \left(\frac{X(t+h) - X(t)}{h}, \frac{X(t+l) - X(t)}{l} \right) \text{ 存在} . \square$$

关于均方可导, 有以下几个性质:

定理 7.2.3 若 $\{X(t), t \in T\}, \{X_k(t), t \in T\}, k = 1, 2$, 在 T 上均方可导, $f(t)$ 为一般函数, 且在 T 上可导, 则:

1° $X_k(t)$ 在 T 上均方连续;

2° 对 $\forall C_1, C_2 \in R, C_1 X_1(t) + C_2 X_2(t)$ 在 T 上均方可导, 且

$$(C_1 X_1(t) + C_2 X_2(t))' = C_1 X_1'(t) + C_2 X_2'(t);$$

3° $\frac{d}{dt}(f(t)X(t)) = \frac{df(t)}{dt}X(t) + f(t)\frac{dX(t)}{dt};$

4° $EX'(t) = \frac{dEX(t)}{dt};$

5° $E(X'(s), X'(t)) = \frac{\partial^2}{\partial s \partial t} R(s, t)$ 其中 $R(s, t) = E(X(s)\overline{X(t)})$.

证明 1° 由均方可导定义得 $\forall t_0 \in T, \lim_{h \rightarrow 0} (X(t_0+h) - X(t_0)) = 0 \Rightarrow \lim_{h \rightarrow 0} X(t_0+h) = \lim_{t \rightarrow t_0} X(t_0)$ 存在, 即 $X(t)$ 在 $\forall t_0 \in T$ 上均方连续;

2° 显然;

3° 左 = $\lim_{h \rightarrow 0} \frac{f(t+h)X(t+h) - f(t)X(t)}{h}$

$$\begin{aligned} \text{右} &= \lim_{h \rightarrow 0} \left(\frac{f(t+h) - f(t)}{h} \right) X(t) + \lim_{h \rightarrow 0} \left(\frac{X(t+h) - X(t)}{h} \right) f(t) \\ &= \lim_{h \rightarrow 0} \frac{[f(t+h) - f(t)]X(t)}{h} + \lim_{h \rightarrow 0} \frac{[X(t+h) - X(t)]f(t+h)}{h} \\ &= \lim_{h \rightarrow 0} \frac{f(t+h)X(t+h) - f(t)X(t)}{h} = \text{左}; \end{aligned}$$

4° 由命题 7.1.2 可得;

5° 由命题 7.1.2 可得.

3° 均方积分

定义 设 $\{X(t), t \in T\}$ 为二阶矩过程. $f(t), t \in T$ 为定义在 T 上的函数, $[a, b] \subset T$, 任取分点 $a = t_0 < t_1 < t_2 < \cdots < t_n = b, \Delta t_k = t_k - t_{k-1}$, 令 $\lambda = \max_{1 \leq k \leq n} \Delta t_k$. 任取 $u_0 \in [t_{k-1}, t_k]$, 若

$$\lim_{\lambda \rightarrow 0} \sum_{k=1}^n f(u_k) X(u_k) \Delta t_k \stackrel{m.s.}{=} \int_a^b f(t) X(t) dt$$

均方极限存在, 则称 $\int_a^b f(t) X(t) dt$ 为 $f(t) X(t)$ 在 $[a, b]$ 上的 R- 均方积分.

若 $\lim_{b \rightarrow \infty, a \rightarrow -\infty} \int_a^b f(t)X(t) dt \stackrel{m.s.}{=} \int_{-\infty}^{+\infty} f(t)X(t) dt$ 均方极限存在, 则称上述极限为 $f(t)X(t)$ 在 $(-\infty, +\infty)$ 上的 R- 均方积分.

均方可积的判定定理如下:

定理 7.2.4(充分条件) 若 $\int_a^b \int_a^b f(s)\overline{f(t)}R(s, t) ds dt$ 存在, 则 $\int_a^b f(t)X(t) dt$ 存在.

证 由命题 7.1.3 可知, $f(t)X(t)$ 在 $[a, b]$ 上均方可积, 即

$$\int_a^b f(t)X(t) dt = \lim_{n \rightarrow \infty} \sum_{k=1}^n f(u_k)X(u_k)\Delta t_k$$

存在的充要条件是:

$$\lim_{n \rightarrow \infty} E\left\{\left[\sum_{k=1}^n f(u_k)X(u_k)\Delta t_k\right]\overline{\left[\sum_{l=1}^m f(u_l)X(u_l)\Delta t'_l\right]}\right\} \quad (*)$$

存在. 根据期望的性质: 有限个 r.v. 线性组合的期望等于各 r.v. 的期望的线性组合. 则

$$\begin{aligned} (*) &= \lim_{n \rightarrow \infty} \left\{ \sum_{k=1}^n \sum_{l=1}^m f(u_k)\overline{f(u_l)}[E(X(u_k)\overline{X(u_l)})]\Delta t_k\Delta t'_l \right\} \\ &= \lim_{n \rightarrow \infty} \left[\sum_{k=1}^n \sum_{l=1}^m f(u_k)\overline{f(u_l)}R(u_k, u_l)\Delta t_k\Delta t'_l \right] \end{aligned}$$

所以当 $\int_a^b \int_a^b f(s)\overline{f(t)}R(s, t) ds dt$ 存在时, $(*)$ 存在, 所以 $\int_a^b f(t)X(t) dt$ 存在.

推论 $\int_{-\infty}^{+\infty} f(t)X(t) dt$ 存在的充分条件是二重积分 $\int_{-\infty}^{+\infty} \int_{-\infty}^{+\infty} f(s)\overline{f(t)}R(s, t) ds dt$ 存在.

下面我们来讨论均方积分的性质:

定理 7.2.5 设 $f(t)X(t), f_k(t)X_k(t)$ ($k = 1, 2$) 在 $[a, b]$ 上均方可积, 则

$$1^\circ \quad E \int_a^b f(t)X(t) dt = \int_a^b f(t)EX(t) dt$$

$$E\left[\left(\int_a^b f(s)X(s) ds\right)\overline{\left(\int_a^b f(t)X(t) dt\right)}\right] = \int_a^b \int_a^b f(s)\overline{f(t)}R(s, t) ds dt$$

$2^\circ \quad \forall C_k \in R, k = 1, 2$, 有 $\int_a^b \sum_{k=1}^2 C_k f_k(t)X_k(t) dt = \sum_{k=1}^2 \int_a^b C_k f_k(t)X_k(t) dt$ (线性性质)

$$3^\circ \quad \int_a^c f(t)X(t) dt + \int_c^b f(t)X(t) dt = \int_a^b f(t)X(t) dt \quad \forall c \in [a, b]$$

证 1° 由 Fubini 定理易得; 2° , 3° 与数学分析中的证明相类似.

更进一步, 我们可以得到均方连续与均方积分的关系.

定理 7.2.6 设 $X(t)$ 在 $[a, b]$ 上均方连续, 则

$$1^\circ \quad X(t) \text{ 在 } [a, b] \text{ 上均方可积, 即 } \int_a^b X(t) dt \text{ 存在;}$$

$$2^\circ \quad \left\| \int_a^b X(t) dt \right\| \leq \int_a^b \|X(s)\| ds;$$

$$3^\circ \quad \text{记 } Y(t) \triangleq \int_a^t X(u) du, (a \leq t \leq b), \text{ 则 } \{Y(t), t \geq 0\} \text{ 在 } [a, b] \text{ 上均方连续, 均方可导, 且 } Y'(t) = X(t).$$

7.2 均方分析

证 1° 由定理 7.2.1 及其推论知, $X(t)$ 在 $[a, b]$ 均方连续 $\Leftrightarrow R(s, t)$ 在 $T \times T$ 上连续 $\Rightarrow \int_a^b \int_a^b R(s, t) ds dt$ 存在. 由定理 7.1.4 得 $X(t)$ 在 $[a, b]$ 均方可积.

2° 由 1° 得 $\int_a^b X(t) dt$ 一定存在. 因为 $\|X(t)\| = (X(t), X(t))^{\frac{1}{2}} = [E(X(t)\overline{X(t)})]^{\frac{1}{2}} = R(t, t)^{\frac{1}{2}}$, 由定理 7.1 得 $\|X(t)\|$ 连续, 从而 $\int_a^b \|X(s)\| ds$ 存在, 因为

$$\left\| \int_a^b X(t) dt \right\| = \left\| \lim_{\lambda \rightarrow 0} \sum_{k=1}^n X(u_k) \Delta t_k \right\| = \lim_{\lambda \rightarrow 0} \left\| \sum_{k=1}^n X(u_k) \Delta t_k \right\|$$

且

$$\left\| \sum_{k=1}^n X(u_k) \Delta t_k \right\| \leq \sum_{k=1}^n \|X(u_k)\| \Delta t_k \quad (\text{距离不等式})$$

所以 $\left\| \int_a^b X(t) dt \right\| \leq \lim_{\lambda \rightarrow 0} \sum_{k=1}^n \|X(u_k)\| \Delta t_k = \int_a^b \|X(t)\| dt$. □

3° 由条件得 $Y(t)$ 在 $[a, b]$ 上均方连续显然. 只需再证 $Y(t)$ 均方可导.

$$\left\| \frac{Y(t+h) - Y(t)}{h} - X(t) \right\| = \left\| \frac{1}{h} \int_t^{t+h} X(u) du - X(t) \right\| = \left\| \frac{1}{h} \int_t^{t+h} (X(s) - X(t)) ds \right\|$$

由 2°

$$\begin{aligned} \left\| \frac{1}{h} \int_t^{t+h} (X(s) - X(t)) ds \right\| &\leq \frac{1}{h} \int_t^{t+h} \|X(s) - X(t)\| ds \\ &\leq \max_{|t-s| \leq h} \|X(s) - X(t)\| \xrightarrow{h \rightarrow 0} 0 \end{aligned}$$

所以 $\lim_{h \rightarrow 0} \frac{Y(t+h) - Y(t)}{h} = X(t)$, 即 $Y(t)$ 在 $[a, b]$ 均方可导, 且 $Y'(t) = X(t)$. □

推论 设 $X(t)$ 在 $[a, b]$ 均方可积, 且 $X'(t)$ 在 $[a, b]$ 上均方连续, 则

$$X(t) - X(a) = \int_a^t X'(s) ds \quad a \leq t \leq b$$

证 因 $X(t) = \int_0^t X'(s) ds$, $X(a) = \int_0^a X'(s) ds$, 则

$$X(t) - X(a) = \int_0^t X'(s) ds - \int_0^a X'(s) ds = \int_a^t X'(s) ds.$$

□

例 B.M. $\{B(t), t \geq 0\}$ 按定义对 $\forall \omega \in \Omega$, 它是 t 的连续函数, 因此第五章中定义的 B.M. 的积分 $S(t) = \int_0^t B(u) du$ 对每一个 $\omega \in \Omega$ 都有定义的. 且 $\{S(t), t \geq 0\}$ 仍是正态过程. 另一方面, 前面已说明 $\{B(t), t \geq 0\}$ 均方连续, 故它均方可积, 记为 $Y(t) = \int_0^t B(u) du$. 由均方收敛唯一性得, $S(t) = Y(t)$, a.e. 且 $\{Y(t), t \geq 0\}$ 仍是正态过程, 均方连续, 其均方导数亦为 $B(t)$.

本节引入伊藤积分的确切定义, 并分析它的主要性质, 特别是 $It\ddot{o}$ 公式.

在 “布朗运动” 一章中, 我们已初步认识到由质点在直线上作随机游动引入的随机微分方程, 为此我们要研究形式如下的积分

$$\int_0^T g(t, w) dB(t, w)$$

不难发现, 这是 $g(t, w)$ 关于 $B(t, w)$ 的 R-S 均方积分. 我们已经知道, B.M. 的轨道性质很特殊, 即几乎任一条轨道的任一点都没有有限的导数, 任意两点之间也没有有限的变差. 因此我们必须对关于 $B(t, w)$ 的 R-S 积分给出与这些性质相对应的定义.

在这一节中, 就是要对这一形式的积分给予确切的数学定义, 在此基础上再研究其重要性质.

设标准 B.M. $\{B(t), t \geq 0\}$ 是定义在概率空间 $(\Omega, \mathcal{F}, \mathcal{P})$ 上的随机过程.

设 $(\mathcal{F}_t, t \geq 0)$ 是一族单调递增的 \mathcal{F} 的子 σ -域, 即 $\mathcal{F}_{t_1} \subset \mathcal{F}_{t_2} \subset \mathcal{F} \quad (\forall t_1 < t_2)$, $\forall \mathcal{F}_t$ 是 \mathcal{F} 的子 σ -域, 且对 $\forall 0 \leq s \leq t$, $B(t)$ 关于 \mathcal{F}_t 可测, $E(B(t)|\mathcal{F}_s) = B(s)$, $E(B(t) - B(s)|\mathcal{F}_s) = 0$.

假设 7.3.1 设随机过程 $\{g(t, w), t \geq 0\}$ 满足以下条件, 对 $T > 0$

1° $g(t, w)$ 关于 $[0, T] \times \Omega$ 可测

2° $\forall t \geq 0, g(t, \cdot)$ 关于 \mathcal{F}_t 可测, 即 $\forall x \in R, (w : g(t, w) \leq x) \in \mathcal{F}_t$

3° $\int_0^T E(g(t, w))^2 dt < \infty, E(g(t, w))^2 < \infty, \forall t \geq 0$

满足假设 7.3.1 的函数全体记作 \mathcal{L}_T^2 .

附注 关于 “可测” 的一点说明

在第一章中, 已经提到了可测空间 (Ω, \mathcal{F}) 与概率空间 (Ω, \mathcal{F}, P) 的概念. 对于某一特定的概率空间 (Ω, \mathcal{F}, P) , 要求随机变量 X 是从 (Ω, \mathcal{F}) 到 (R, \mathcal{B}) (\mathcal{B} 是定义在 R 上的 Borel 集) 是可测函数 (或可测映射), 其一个主要目的是使对于 $\forall B \in \mathcal{B}, (w : X(w) \in B) \in \mathcal{F}$ 成立. 这样就使得在 (Ω, \mathcal{F}, P) 中事件 $(w : X(w) \in B)$ 可以定义其概率 (测度), 即 $P(w : X(w) \in B)$ 有意义.

在 $It\ddot{o}$ 积分中, 可测性同样具有重要的前提意义. 首先, 对于给定的概率空间 (Ω, \mathcal{F}, P) , 二元函数 $\{g(t, w), 0 \leq t \leq T\}$ 关于可测空间 $([0, T] \times \Omega, \mathcal{B}[0, T] \times \mathcal{F})$ 可测, 是使得积分 $\int_0^T g(t, w) dB(t, w)$ 有意义的基础. 同时对于给定的 T , $\int_0^T g(t, w) dB(t, w)$ 也是关于 (Ω, \mathcal{F}) 可测的, 即概率测度 $P(w : \int_0^T g(t, w) dB(t, w) \leq x)$ 是有意义的. 从而对于变化的 $0 \leq t \leq T$, $\int_0^t g(s, w) dB(s, w)$ 构成一个随机过程. 其次, 对 $\forall 0 \leq t \leq T, g(t, \cdot)$ 关于 \mathcal{F}_t 可测 (即 $\forall x \in R, (w : g(t, w) \leq x) \in \mathcal{F}_t$) 使得 $E(g(t)|\mathcal{F}_t) = g(t)$ 成立. 正是这个事实, 赋予了 $It\ddot{o}$ 积分许多重要而简洁的性质. 以下内容, 将不断说明这一点.

定义 设 $(B(t), t \geq 0)$ 为标准 B.M., $\{g(t, w), t \geq 0\}$ 满足假设 7.3.1, 即 $g \in \mathcal{L}_T^2$, $[0, t] \subset [0, T]$. 任取 $\forall 0 \leq t_0 < t_1 < t_2 < \cdots < t_n \leq t$, 令 $\Delta t_k = t_k - t_{k-1} \quad (1 \leq k \leq n)$,

7.3 伊藤 (Itô) 随机积分

$\lambda = \max_{1 \leq k \leq n} \Delta t_k$. 若

$$\lim_{\lambda \rightarrow 0} \sum_{k=1}^n g(t_{k-1})(B(t_k) - B(t_{k-1})) \stackrel{m.s.}{=} Ig(t) \quad (7.3.1)$$

均方极限存在. 则称 $Ig(t) = \int_0^t g(s, w) dB(s, w)$ 为 $\{g(t, w), t \geq 0\}$ 关于 $\{B(t), t \geq 0\}$ 在 $[0, t]$ 的 **Itô 积分**.

注意 Itô 积分的定义中, 求极限项中 $g(t)$ 取的是左端点. 一般地取其他端点会导致极限值不同, 甚至不存在.

例 B.M. 的轨道性质表明

$$\begin{aligned} \lim_{\lambda \rightarrow 0} \sum_{k=1}^n B(t_{k-1})(B(t_k) - B(t_{k-1})) &\stackrel{m.s.}{=} \frac{1}{2} B^2(t) - \frac{t}{2} \\ \lim_{\lambda \rightarrow 0} \sum_{k=1}^n B(t_k)(B(t_k) - B(t_{k-1})) &\stackrel{m.s.}{=} \frac{1}{2} B^2(t) + \frac{t}{2} \end{aligned}$$

为了研究 Itô 积分的性质, 我们从简单入手. 设 $\{g(t, w), t \geq 0\}$ 是 $[0, t]$ 上的台阶形函数 (即 $g(t, w)$ 是示性函数的线性组合, 又称为简单函数). 则对 $0 = t_0 < t_1 < \cdots < t_n = t$, 有 $g(t) = \sum_{k=1}^n g_{k-1}(w) \cdot I_{(t_{k-1} \leq t \leq t_k)}(t)$, ($g_{k-1}(w)$ 关于 $\mathcal{F}_{t_{k-1}}$ 可测). 不妨设 $\mathcal{F}_t = \sigma(B(s), 0 \leq s \leq t) = \sigma(B(t_k), 1 \leq k \leq n, t_k \leq t, n \geq 1)$, 则 $g(t, w)$ 关于 $B(t)$ 的 Itô 积分为

$$I(g) = \sum_{k=1}^n g_{k-1}((B(t_k) - B(t_{k-1})))$$

因此

$$EI(g) = \sum_{k=1}^n E[g_{k-1}(B(t_k) - B(t_{k-1}))] = \sum_{k=1}^n E[g_{k-1} \cdot E(B(t_k) - B(t_{k-1}) | B(t_{k-1}))] = 0$$

$$\begin{aligned} E(I(g)^2) &= DI(g) = \sum_{k=1}^n E(g_{k-1}^2 E[(B(t_k) - B(t_{k-1}))^2 | B(t_{k-1})]) \\ &= \sum_{k=1}^n E g_{k-1}^2 (t_k - t_{k-1}) = \int_0^t E(g^2(s)) ds \end{aligned}$$

对于简单函数的 Itô 积分, 我们还可以很简便地得到下面的性质. 若 $\alpha_i \in R$, $g_i (i = 1, 2)$ 都是满足上述条件的简单函数, 则有

$$I(\alpha_1 g_1 + \alpha_2 g_2) = \alpha_1 I(g_1) + \alpha_2 I(g_2) \quad (\text{线性关系})$$

若记 $S(t) = \int_0^t g(s) dB(s)$ (其中 g 为台阶形函数), 则 $\forall t_1 < t_2$, 容易验证

$$E(S(t_2) - S(t_1) | B(t_1)) = 0$$

即 $E(S(t_2)|B(t_1)) = E(S(t_1)|B(t_1)) = S(t_1)$, 这就意味着, $S(t) = \int_0^t g(s) dB(s)$ 关于 $\{B(t), t \geq 0\}$ 是鞅.

另外, $I(g)$ 的可加性质也很显然. 记 $I_g(0, t) = \int_0^t g(s) dB(s)$, 则

$$I_g(0, t) = I_g(0, t_1) + I_g(t_1, t) \quad \forall 0 \leq t_1 \leq t$$

一般地, 对 $\forall g(t) \in \mathcal{L}_T^2$, $I_g(t) \triangleq I_g(0, t) \triangleq \int_0^t g(s) dB(s)$. 由概率论随机变量分解可知, 存在 $\{g_n(t), n \geq 1\}$, $g_n(t) \in \mathcal{L}_T^2$ 为台阶形函数 (简单函数), 当 $n \uparrow$ 时 $\{g_n(t), t \geq 1\}$ 是单调不减序列, 且 $g_n(t) \uparrow g(t)$, 故由 Lebesgue Dominated Convergence Theorem (勒贝格控制收敛定理) 知

$$I_g(t) = \lim_{n \rightarrow \infty} \int_0^t g_n(s) dB(s) = \lim_{n \rightarrow \infty} I_{g_n}(t)$$

因此, 由 $I_{g_n}(t)$ 的性质, 可以推广到对一般满足假设 7.3.1 条件的 Itô 积分有如下的性质:

$\forall g, g_1, g_2 \in \mathcal{L}_T^2$, 记 $I_g(t) = I_g(0, t)$

$$1^\circ \quad EI_g(t) = 0 \quad (7.3.2)$$

$$2^\circ \quad EI_g^2(t) = \int_0^t Eg^2(s) ds, (I_g(s), I_g(t)) = \int_0^s Eg^2(u) du. (\forall 0 \leq s \leq t) \quad (7.3.3)$$

$$3^\circ \quad I_{\alpha_1 g_1 + \alpha_2 g_2}(t) = \alpha_1 I_{g_1}(t) + \alpha_2 I_{g_2}(t), (\forall \alpha_1, \alpha_2 \in R) \quad (7.3.4)$$

$$4^\circ \quad I_g(0, t) = I_g(0, t_1) + I_g(t_1, t). (\forall 0 \leq t_1 \leq t) \quad (7.3.5)$$

$5^\circ \quad \{I_g(t) = \int_0^t g(s) dB(s), t \geq 0\}$ 关于 \mathcal{F}_t 是鞅

$6^\circ \quad (\text{Doob 极大值不等式})$ 令 $X(t) = \int_0^t g(s) dB(s)$, 则 $\forall t \geq 0, \lambda > 0, p \geq 1$

$$P(\max_{0 \leq u \leq t} |X(u)| > \lambda) \leq \frac{E(X(t))^p}{\lambda^p} \quad (7.3.6)$$

证明 只证 2° :

$$\begin{aligned} \forall 0 \leq s \leq t, (I_g(s), I_g(t)) &= E\left[\int_0^s g(u) dB(u) \int_0^t g(v) dB(v)\right] \\ &= \int_0^s \int_0^t g(u)g(v) E(dB(u) dB(v)) \quad (\text{Fubini 定理}) \end{aligned}$$

因为当 $v \neq u$ 时, 总能取和式中积分小区间不重叠, 则由 B.M. 性质有

$$E(dB(u) dB(v)) = 0$$

只有当 $v = u$ 时, 才可得到 $E(dB(u) dB(v)) = du = dv$. 所以上面的二重积分, 相当于对角线上的积分, 即 $(I_g(s), I_g(t)) = \int_0^s Eg^2(u) du$. 其他证明很简单, 此处略去.

注 性质 5° 说明了由 Itô 积分定义的过程一定是鞅. 事实上, 其逆命题也成立, 即:

7.4 Itô 随机过程与 Itô 公式

若 $\{X(t), t \geq 0\}$ 是鞅, $X(t) \in \mathcal{L}_T^2$, 则必存在唯一的自适应过程 $\{g(t), t \geq 0\}$ (即 $g(t) \in \mathcal{L}_T^2$), 满足 $0 \leq t_0 \leq t \leq T$,

$$X(t) - X(t_0) = \int_{t_0}^t g(s) dB(s)$$

这就是著名的 **鞅表示定理**.

例 求 $\int_0^t B(s) dB(s)$ (设 $B(0) = 0$)

求解可以根据定义完成: 显然 $B(t) \in \mathcal{L}_T^2, \forall 0 = t_0 < t_1 < \cdots < t_n = t, \Delta t_k = t_k - t_{k-1}$, 令 $\lambda = \max_{1 \leq k \leq n} \Delta t_k$. 记 $B_k = B(t_k), \Delta B_k = B(t_k) - B(t_{k-1})$,

$$\begin{aligned} \Delta(B_k^2) &= B_k^2 - B_{k-1}^2 = (B_k - B_{k-1})^2 + 2B_{k-1}(B_k - B_{k-1}) \\ &= (\Delta B_k)^2 + 2B_{k-1}\Delta B_k \end{aligned}$$

所以 $B^2(t) = \sum_{k=1}^n \Delta(B_k^2) = \sum_{k=1}^n (\Delta B_k)^2 + 2 \sum_{k=1}^n B_{k-1} \Delta B_k$, 即 $\sum_{k=1}^n B(t_{k-1}) \Delta B_k = \frac{1}{2} B^2(t) - \frac{1}{2} \sum_{k=1}^n (\Delta B_k)^2$. \square

在第五章中, 我们已知 B.M. 的轨道性质

$$E\left(\sum_{k=1}^n (\Delta B_k)^2 - t\right)^2 = E\left(\sum_{k=1}^n [(\Delta B_k)^2 - \Delta t_k]\right)^2 \xrightarrow{m.s.} 0 \quad (\lambda \rightarrow 0)$$

即 $\sum_{k=1}^n (\Delta B_k)^2 \xrightarrow{m.s.} t \quad (\lambda \rightarrow 0)$, 所以

$$\int_0^t B(s) dB(s) = \lim_{\lambda \rightarrow 0} \sum_{k=1}^n B(t_{k-1})(B(t_k) - B(t_{k-1})) \xrightarrow{m.s.} \frac{1}{2} B^2(t) - \frac{t}{2}$$

同理, 还可以得到 $\int_a^b B(s) dB(s) = \frac{1}{2}(B^2(b) - B^2(a)) - \frac{1}{2}(b - a)$.

§ 7.4 Itô 随机过程与 Itô 公式

上一节定义了 Itô 积分的概念, 但是它应该怎么计算呢? 通常用 Itô 积分的定义直接计算是相当困难的. 为此, 在本书中, 介绍 Itô 积分的一个重要法则 — Itô 公式. 它可以看作是与通常微积分中的复合函数求微分相对应的法则, 但 Itô 公式与通常的复合函数求导法则在形式上有很大不同.

定义 设随机过程 $X = \{X(t), t \geq 0\}$, 满足如下的 Itô 积分: $\forall 0 \leq t_0 < t < T$

$$X(t) - X(t_0) = \int_{t_0}^t b(s) ds + \int_{t_0}^t \sigma(s) dB(s) \quad (7.4.1)$$

或等价地写作 Itô 微分形式 248

$$dX(t) = b(t) dt + \sigma(t) dB(t) \quad (7.4.2)$$

其中 $|b(t)|^{\frac{1}{2}}, \sigma(t) \in \mathcal{L}_T^2$ (即满足假设 7.2.1), 则称 X 为 $It\ddot{o}$ 随机过程(简称 $It\ddot{o}$ 过程)

在 $It\ddot{o}$ 随机过程的定义式 7.4.1 中, $\int_{t_0}^t b(s) ds$ 是一般的均方积分, 而 $\int_{t_0}^t \sigma(s) dB(s)$ 则是 $It\ddot{o}$ 积分.

本节中所讨论的问题就是: 若一随机过程 $Y = \{Y(t), t \geq 0\}$ 是 $It\ddot{o}$ 过程 X 的函数, 如何求它的微分 $dY(t)$? $Y(t)$ 是否可以表示为 $It\ddot{o}$ 积分? 如果可以, 则又需要哪些条件? 下面介绍的 $It\ddot{o}$ 公式就是回答这些问题的.

定理 7.4.1 设 $X = \{X(t), t \geq 0\}$ 满足等式 (7.4.1), $y = f(t, x)$ 是二元函数, 且具有连续偏导数 $\frac{\partial f}{\partial t}, \frac{\partial f}{\partial x}, \frac{\partial^2 f}{\partial x^2}$, 令 $Y(t) \triangleq f(t, X(t))$, 则过程 $Y = \{Y(t), t \geq 0\}$ 也是随机过程, 且对 $\forall 0 \leq t_0 < t \leq T$ 满足如下的 $It\ddot{o}$ 积分方程:

$$Y(t) - Y(t_0) = \int_{t_0}^t \left[\frac{\partial f}{\partial t} + b \cdot \frac{\partial f}{\partial x} + \frac{\sigma^2}{2} \frac{\partial^2 f}{\partial x^2} \right](s, X(s)) ds + \int_{t_0}^t \sigma \frac{\partial f}{\partial x}(s, X(s)) dB(s). \quad (7.4.3)$$

或等价的 $It\ddot{o}$ 微分形式

$$dY(t) = \left(\frac{\partial f}{\partial t} + b \frac{\partial f}{\partial x} + \frac{\sigma^2}{2} \frac{\partial^2 f}{\partial x^2} \right)(t, X(t)) dt + \sigma \frac{\partial f}{\partial x}(t, X(t)) dB(t) \quad (a.e.) \quad (7.4.4)$$

(7.4.3) 或 (7.4.4) 即是 $It\ddot{o}$ 公式.

$It\ddot{o}$ 公式有非常广泛的应用, 下面举例说明之.

例 1 用 $It\ddot{o}$ 公式求 $\int_0^t B(s) dB(s)$

令 $X(t) = B(t)$, 则 $dX(t) = 0 \cdot dt + 1 \cdot dB(t)$, 令 $f(t, x) = \frac{1}{2}x^2$, $Y(t) = \frac{1}{2}f(t, B(t)) = \frac{1}{2}B^2(t)$. 所以 $b = 0$, $\sigma = 1$, $\frac{\partial f}{\partial t} = 0$, $\frac{\partial f}{\partial x} = x$, $\frac{\partial^2 f}{\partial x^2} = 1$. 则

$$\begin{aligned} dY(t) &= \sigma \frac{\partial f}{\partial x} dB(t) + \left[\frac{\partial f}{\partial t} + b \frac{\partial f}{\partial x} + \frac{\sigma^2}{2} \frac{\partial^2 f}{\partial x^2} \right] dt \\ &= B(t) dB(t) + \left(0 + 0 + \frac{1}{2} \right) dt \end{aligned}$$

即 $d(\frac{1}{2}B^2(t)) = B(t) dB(t) + \frac{1}{2} dt$. 写成积分形式为 $\int_0^t d(\frac{1}{2}B^2(s)) = \int_0^t B(s) dB(s) + \frac{1}{2} \int_0^t ds$. 于是得 $\int_0^t B(s) dB(s) = \frac{1}{2}B^2(t) - \frac{t}{2}$. \square

将例 1 与上一节利用 $It\ddot{o}$ 积分定义求 $\int_0^t B(s) dB(s)$ 可发现, $It\ddot{o}$ 公式为我们提供了一个更简捷的工具.

例 2 人口增长模型: 设 $N(t)$ 为 t 时刻的人口数, 且 $\{N(t), t \geq 0\}$ 满足

$$dN(t) = \gamma N(t) dt + \alpha N(t) dB(t)$$

其中 γ, α 为常数.

令 $B(0) = 0$, 得 $\int_0^t \frac{dN(t)}{N(t)} = \gamma t + \alpha B(t)$. 令 $f(t, x) = \ln x$, $Y(t) = \ln N(t)$, 则 $\frac{\partial f}{\partial t} = 0$, $\frac{\partial f}{\partial x} = \frac{1}{x}$, $\frac{\partial^2 f}{\partial x^2} = -\frac{1}{x^2}$. 由 (7.4.4) 式, 有:

$$dY(t) = d \ln N(t) = \left[\gamma N(t) \cdot \frac{1}{N(t)} + 0 + \frac{\alpha^2 N^2(t)}{-2N^2(t)} \right] dt + \alpha N(t) \frac{1}{N(t)} dB(t)$$

7.4 Itô 随机过程与 Itô 公式

即:

$$d(\ln N(t)) = (\gamma - \frac{\alpha^2}{2}) dt + \alpha dB(t)$$

当 $B(0) = 0$ 时, 得

$$\ln \frac{N(t)}{N(0)} = (\gamma - \frac{\alpha^2}{2})t + \alpha B(t)$$

所以

$$N(t) = N(0)e^{(\gamma - \frac{\alpha^2}{2})t} \cdot e^{\alpha B(t)}.$$

可见 $N(t)$ 是几何 B.M. 的变形.

讨论: 当 $2\gamma > \alpha^2$ 时, $t \rightarrow \infty$, 则 $N(t) \xrightarrow{a.e.} +\infty$

当 $2\gamma < \alpha^2$ 时, $t \rightarrow \infty$, 则 $N(t) \xrightarrow{a.e.} 0$

当 $2\gamma = \alpha^2$ 时, $N(t) = N(0)e^{\alpha B(t)}$ 随机波动

$$\begin{aligned} EN(t) &= E[N(0)e^{(\gamma - \frac{\alpha^2}{2})t} \cdot e^{\alpha B(t)}] = N(0)e^{(\gamma - \frac{\alpha^2}{2})t} Ee^{\alpha B(t)} \\ &= N(0)e^{(\gamma - \frac{\alpha^2}{2})t} \int_{-\infty}^{+\infty} e^{\alpha x} \frac{1}{\sqrt{2\pi t}} e^{-\frac{x^2}{2t}} dx \\ &= \frac{1}{\sqrt{2\pi t}} N(0)e^{(\gamma - \frac{\alpha^2}{2})t} \int_{-\infty}^{+\infty} e^{(\alpha x - \frac{x^2}{2t})} dx \end{aligned}$$

附 Itô 公式证明. 这里只给出简要梗概, 详细证明参见参考书 [2].

引理: 设 $y = f(t, x)$ 是 $[0, T] \times R \rightarrow R$ 的二元函数, 它有连续的偏导数 $\frac{\partial f}{\partial t}, \frac{\partial f}{\partial x}, \frac{\partial^2 f}{\partial x^2}$, 则对 $\forall [t, t + \Delta t] \subset [0, T], (x, x + \Delta x) \in R$. 存在常数 $0 \leq \alpha, \beta \leq 1$, 满足

$$f(t + \Delta t, x + \Delta x) - f(t, x) = \frac{\partial f}{\partial t}(t + \alpha \Delta t, x) \Delta t + \frac{\partial f(t, x)}{\partial x} \Delta x + \frac{1}{2} \frac{\partial^2 f(t, x + \beta \Delta x)}{\partial x^2} (\Delta x)^2$$

(即微分中值定理)

记 $\Delta X(t) = X(t + \Delta t) - X(t)$, 于是

$$\begin{aligned} \Delta Y(t) &= f(t + \Delta t, X(t + \Delta t)) - f(t, X(t)) \\ &= \frac{\partial f}{\partial t}(t + \alpha \Delta t, X(t)) \cdot \Delta t + \frac{\partial f}{\partial x}(t, X(t)) \Delta X(t) + \frac{1}{2} \frac{\partial^2 f}{\partial x^2}(t, X(t) + \beta \Delta X(t)) (\Delta X(t))^2 \\ &\triangleq A + B + C \end{aligned}$$

由 $\frac{\partial f}{\partial t}, \frac{\partial f}{\partial x}, \frac{\partial^2 f}{\partial x^2}$ 连续, $dX(t) = \sigma(t) dB(t) + b(t) dt$, 即

$$\Delta X(t) - (b(t)\Delta t + \sigma(t)\Delta B(t)) \stackrel{m.s.}{=} o(\Delta t)$$

所以

$$\begin{aligned}
 A &= \frac{\partial f}{\partial t}(t, X(t))(\Delta t + o(\Delta t)) \\
 B &\stackrel{m.s.}{=} \frac{\partial f(t, X(t))}{\partial x}(\sigma(t)\Delta B(t) + b(t)\Delta t + o(\Delta t)) \\
 &\stackrel{m.s.}{=} \sigma(t) \frac{\partial f(t, X(t))}{\partial x} dB(t) + b(t) \frac{\partial f(t, X(t))}{\partial x} \Delta t + o(\Delta t) \\
 C &\stackrel{m.s.}{=} \frac{1}{2} \frac{\partial^2}{\partial x^2} f(t, X(t)) [\sigma^2(t)(\Delta B(t))^2 + b^2(t)(\Delta t)^2 + 2\sigma(t)\Delta B(t)b(t)\Delta t + o(\Delta t)] \\
 &\stackrel{m.s.}{=} \frac{1}{2} \frac{\partial^2}{\partial x^2} \sigma^2(t) \Delta t + o(\Delta t)
 \end{aligned}$$

故:

$$\Delta Y(t) \stackrel{m.s.}{=} \sigma(t) \frac{\partial f(t, X(t))}{\partial x} dB(t) + \left(\frac{\partial f}{\partial t} + b(t) \frac{\partial f}{\partial x} + \frac{\sigma^2}{2} \frac{\partial^2 f}{\partial x^2} \right)(t, X(t)) \Delta t + o(\Delta t)$$

所以

$$dY(t) = \sigma(t) \frac{\partial f}{\partial x}(t, X(t)) dB(t) + \left(\frac{\partial f}{\partial t} + b(t) \frac{\partial f}{\partial x} + \frac{\sigma^2}{2} \frac{\partial^2 f}{\partial x^2} \right)(t, X(t)) dt. \quad \square$$

将上述 Itô 积分, 推广到向量空间, 可得向量 Itô 积分.

令 $B(t) = (B_1(t), \dots, B_m(t))^T$ 是 m 维标准 B.M., 即 $\{B(t), t \geq 0\}$ 满足:

1° $B(t)$ 是 m 维独立增量过程

2° $\forall s, t \geq 0, B(s+t) - B(s) \sim N(0, tI)$. 其中 I 为 m 维单位矩阵, 即它的 p.d.f. 为

$$f(t, x) = \frac{1}{(2\pi t)^{\frac{m}{2}}} e^{-\frac{x^2}{2t}}, \quad (t, x) \in [0, t] \times R. \quad \text{其中 } x = (x_1, \dots, x_m) \in R^m, x^2 = \sum_{i=1}^m x_i^2.$$

设 $b(t) = (b_1(t), \dots, b_n(t))^T$

$$\Sigma(t) = (\sigma_{ij}(t)) = \begin{bmatrix} \sigma_{11}(t) & \cdots & \sigma_{1m}(t) \\ \vdots & & \vdots \\ \sigma_{n1}(t) & \cdots & \sigma_{nm}(t) \end{bmatrix}$$

且 $|b_i(t)|^{\frac{1}{2}}, \sigma_{ij}(t) \in \mathcal{L}_T^2, \forall 1 \leq i \leq n, 1 \leq j \leq m$ 且是 \mathcal{F}_t 可测的. 其中 $\mathcal{F}_t = \sigma(B_i(s_i), s_i \leq t, 1 \leq i \leq m)$. 若 $\{X(t) = (X_1(t), \dots, X_n(t))^T, t \geq 0\}$ 满足

$$\begin{cases} dX_1(t) = b_1(t) dt + \sigma_{11}(t) dB_1(t) + \sigma_{12}(t) dB_2(t) + \cdots + \sigma_{1m}(t) dB_m(t) \\ dX_2(t) = b_2(t) dt + \sigma_{21}(t) dB_1(t) + \sigma_{22}(t) dB_2(t) + \cdots + \sigma_{2m}(t) dB_m(t) \\ \dots \\ dX_n(t) = b_n(t) dt + \sigma_{n1}(t) dB_1(t) + \sigma_{n2}(t) dB_2(t) + \cdots + \sigma_{nm}(t) dB_m(t) \end{cases} \quad (7.4.5)$$

或写成向量形式

$$dX(t) = b(t) dt + \Sigma(t) dB(t) \quad (7.4.6)$$

称 $X = \{X(t), t \geq 0\}$ 为 n 维 Itô 随机过程.

定理 7.4.2(多元 Itô 公式) 设 $\{X(t), t \geq 0\}$ 是 n 维 Itô 过程, 满足 $dX(t) = b(t) dt + \Sigma(t) dB(t)$. $f(t, x) = (f_1(t, x), \dots, f_d(t, x))^T$ 是 $[0, \infty) \times R^n \rightarrow R^d$ 上的函数. 其中 $x = (x_1, \dots, x_n)$, 且 $\frac{\partial f_k}{\partial t}, \frac{\partial f_k}{\partial x}, \frac{\partial^2 f_k}{\partial x_i \partial x_j}$ 偏导数连续. $1 \leq k \leq d, 1 \leq i, j \leq n$. 则随机过程 $\{Y(t) = f(t, X(t)), t \geq 0\}$ 是 d 维 Itô 随机过程, 且

$$\begin{aligned} dY_k(t) = & \left(\frac{\partial f_k}{\partial t} + \sum_{i=1}^n b_i \frac{\partial f_k}{\partial x_i} + \frac{1}{2} \sum_{i=1}^n \sum_{j=1}^n \sum_{l=1}^m \frac{\partial^2 f_k}{\partial x_i \partial x_j} \sigma_{il} \sigma_{jl} \right)(t, X(t)) dt \\ & + \sum_{l=1}^m \left(\sum_{i=1}^n \frac{\partial f_k}{\partial x_i} \sigma_{il} \right)(t, X(t)) dB_l(t), 1 \leq k \leq d \end{aligned} \quad (7.4.7)$$

证 多元 Itô 公式的证明类似于二维 Itô 公式的证明, 故此处从略.

例 二元 Itô 公式的举例

设 $X(t) = (X_1(t), X_2(t))$ 满足

$$\begin{pmatrix} dX_1(t) \\ dX_2(t) \end{pmatrix} = \begin{pmatrix} b_1(t) \\ b_2(t) \end{pmatrix} dt + \begin{pmatrix} b_1(t) & 0 \\ 0 & b_2(t) \end{pmatrix} \begin{pmatrix} dB_1(t) \\ dB_2(t) \end{pmatrix}$$

令 $f(t, x) = x_1 \cdot x_2, Y(t) = X_1(t) \cdot X_2(t)$, 则

$$dY(t) = (b_1(t)X_2(t) + b_2(t)X_1(t)) dt + b_1(t)X_2(t) dB_1(t) + b_2(t)X_1(t) dB_2(t) \quad (7.4.8)$$

§ 7.5 Itô 随机微分方程 (Itô Stochastic Differentiated Equations)

前面在 Itô 公式中我们接触了随机微分方程, 那么, 给定一个随机微分方程, 它的解是否存在? 如果存在, 是否唯一? 有什么性质? 因此如何求解一个随机微分方程成为解答这些问题的基础. 这一节中, 我们先着手讨论一些简单随机微分方程的求解方法.

1. 常系数的线性随机微分方程

例 1 设 $\{X(t), t \geq 0\}$ 满足 Ornstein-Uhlenbeck 方程

$$dX(t) = -\mu X(t) dt + \sigma dB(t) \quad (\mu, \sigma \text{ 为常数}) \quad (7.5.1)$$

求解 $X(t)$

解: 将方程化为 $dX(t) + \mu X(t) dt = \sigma dB(t)$

两边同乘上 $e^{\mu t}$, 即

$$e^{\mu t} (dX(t) + \mu X(t) dt) = \sigma e^{\mu t} dB(t)$$

亦即

$$d(X(t)e^{\mu t}) = \sigma e^{\mu t} dB(t)$$

两边从 t_0 到 t 积分, $(\forall 0 \leq t_0 < t \leq T)$, 有

$$X(t)e^{\mu t} - X(t_0)e^{\mu t_0} = \int_{t_0}^t \sigma e^{\mu s} dB(s)$$

得

$$X(t) = X(t_0)e^{-\mu(t-t_0)} + \int_{t_0}^t \sigma e^{-\mu(t-s)} dB(s) \quad (7.5.2)$$

□

2. 简单的线性齐次随机微分方程

例 2 人口增长模型 (见上节例 2)

用 Itô 公式求解积分 $\int_0^t \frac{dN(t)}{dt}$, 得

$$N(t) = N(0)e^{(\gamma - \frac{\sigma^2}{2})t + \alpha B(t)} \quad (7.5.3)$$

例 3 Black-Scholes model

设 $S(t)$ 为 t 时刻某种股票 (证券) 价格, 在某些条件下它满足以下随机微分方程:

$$\begin{cases} dS(t) = S(t)(\mu dt + \sigma dB(t)) \\ S(0) = S_0 \end{cases} \quad \text{其中 } \mu, \sigma \text{ 为常数} \quad (7.5.4)$$

该模型与上例人口模型类似, 用相同方法即可求得

$$S(t) = S_0 e^{(\mu - \frac{\sigma^2}{2})t + \sigma B(t)} \quad (7.5.5)$$

是它的解. 它也是一个几何 B.M. 过程.

3. 一般的线性非齐次随机微分方程

设 $\{X(t), t \geq 0\}$ 满足

$$\begin{cases} dX(t) = (a_1(t)X(t) + a_2(t))dt + (b_1(t)X(t) + b_2(t))dB(t) \\ X(t_0) = x \end{cases} \quad \text{(初始条件)} \quad (7.5.6)$$

其中 $\{B(t), t \geq 0\}$ 是一维标准 B.M., $a_1(t), a_2(t), b_1(t), b_2(t)$ 是 t 的一般函数 (也可以是常数). 设它们在 $[0, t]$ 上 Borel 可测¹ 且有界, 设 $0 \leq t_0 < t \leq T$, 初始值 $X(t_0)$ 关于 \mathcal{F}_{t_0} 可测.

求解 $X(t)$ 的显示表达式.

¹容易验证, 单调函数, 逐段单调函数及连续函数均是 Borel 可测函数

7.5 Itô 随机微分方程

我们由易入难地着手. 在 (7.4.6) 中若 $a_2(t) \equiv b_2(t) \equiv 0$, 则称方程

$$dX(t) = a_1(t)X(t)dt + b_1(t)X(t)dB(t) \quad (7.5.7)$$

为 **齐次线性随机微分方程**.

在 (7.4.6) 中若 $b_1(t) \equiv 0$, 则称方程

$$dX(t) = (a_1(t)X(t) + a_2(t))dt + b_2(t)dB(t) \quad (7.5.8)$$

为 **狭义下的线性随机微分方程**. 考虑狭义 SDE 的解法.

(1) 先求解 (7.5.8) 对应的齐次方程, 即

$$dX(t) = a_1(t)X(t)dt \quad (7.5.9)$$

亦即 $\frac{dX(t)}{X(t)} = a_1(t)dt$.

上式中变量已经分离, 两边从 t_0 到 t 积分 ($\forall 0 \leq t_0 < t < T$), 可得到它的一个解为 $\rho_{t_0}(t) = \exp(\int_{t_0}^t a_1(u)du)$

(2) 求解 (7.5.8) 所示狭义 SDE

令 $y = f(t, x) = \rho_{t_0}^{-1}(t)x$, 则 $\frac{\partial f}{\partial t} = -\rho_{t_0}^{-1}(t)a_1(t)$, $\frac{\partial f}{\partial x} = \rho_{t_0}^{-1}(t)$, $\frac{\partial^2 f}{\partial x^2} = 0$

对于 $X(t)$ 所满足的 (7.4.8) 式有 $b(t) \triangleq a_1(t)X(t) + a_2(t)$, $\sigma(t) \triangleq b_2(t)$ 即 $dX(t) = b(t)dt + \sigma(t)dB(t)$. 令 $Y(t, X(t)) = \rho_{t_0}^{-1}(t)X(t)$, 于是利用 Itô 公式有

$$\begin{aligned} dY(t, X(t)) &= d(\rho_{t_0}^{-1}(t)X(t)) \\ &= b_2(t)\rho_{t_0}^{-1}(t)dB(t) + [-\rho_{t_0}^{-1}(t)a_1(t)X(t) + (a_1(t)X(t) + a_2(t))\rho_{t_0}^{-1}(t)]dt \end{aligned}$$

所以 $d(\rho_{t_0}^{-1}(t)X(t)) = a_2(t)\rho_{t_0}^{-1}(t)dt + b_2(t)\rho_{t_0}^{-1}(t)dB(t)$, 注意到 $\rho_{t_0}(t_0) = 1$, 对上式两边积分, 有

$$\rho_{t_0}^{-1}(t)X(t) = X(t_0) + \int_{t_0}^t a_2(s)\rho_{t_0}^{-1}(s)ds + \int_{t_0}^t b_2(s)\rho_{t_0}^{-1}(s)dB(s)$$

所以 $X(t) = \rho_{t_0}(t)[X(t_0) + \int_{t_0}^t a_2(s)\rho_{t_0}^{-1}(s)ds + \int_{t_0}^t b_2(s)\rho_{t_0}^{-1}(s)dB(s)]$ 是方程 (7.5.8) 的一个解.

注意 当 $a_1(t) = -a$, $a_2(t) \equiv b_1(t) \equiv 0$, $b_2(t) = b$ 时, (7.4.8) 即转化为 Langevin 方程

$$dX(t) = -a dt + b dB(t)$$

由上述求解过程得到的解与前面的结果完全一致.

现在, 我们来解一般的线性 SDE, 仍然从它相对应的齐次 SDE 开始

(1) 求解齐次 SDE(7.5.7)

令 $y(t) = \ln x$, 即 $\frac{\partial f}{\partial t} = 0$, $\frac{\partial f}{\partial x} = \frac{1}{x}$, $\frac{\partial^2 f}{\partial x^2} = -\frac{1}{x^2}$. 令 $Y(t) = \ln X(t)$, 对方程 (7.5.7) 利用 Itô 公式有:

$$dY(t) = d\ln X(t) = [a_1(t)X(t) \cdot \frac{1}{X(t)} + \frac{b_1^2(t)X^2(t)}{2}(-\frac{1}{X^2(t)})]dt + b_1(t)X(t) \cdot \frac{1}{X(t)}dB(t)$$

所以

$$d\ln X(t) = [a_1(t) - \frac{1}{2}b_1^2(t)]dt + b_1(t)dB(t)$$

两边积分

$$\ln X(t) - \ln X(t_0) = \int_{t_0}^t (a_1(s) - \frac{b_1(s)}{2})ds + \int_{t_0}^t b_1(s)dB(s)$$

不妨取 $X(t_0) = 1$ (作为特解), 则 $\ln X(t_0) = 0$, 所以

$$\ln X(t) = \int_{t_0}^t (a_1(s) - \frac{b_1(s)}{2})ds + \int_{t_0}^t b_1(s)dB(s)$$

故取

$$\rho_{t_0}(t) = \exp[\int_{t_0}^t (a_1(s) - \frac{b_1(s)}{2})ds + \int_{t_0}^t b_1(s)dB(s)] \quad (7.5.10)$$

作为方程 (7.4.7) 的一个基本解, 即它满足

$$d\rho_{t_0}(t) = a_1(t)\rho_{t_0}(t)dt + b_1(t)\rho_{t_0}(t)dB(t) \quad (7.5.10.a)$$

(2) 求解一般线性 SDE(7.5.6)

先利用上一节中定理 7.3.2 给出一个特殊的多元 Itô 公式, 设 $\{X_i(t), t \geq 0\}$, $i = 1, 2$, 满足

$$dX_i(t) = b_i(t)dt + \sigma_i(t)dB(t) \quad i = 1, 2$$

令 $f(t, x_1, x_2) = x_1 \cdot x_2$, $Y(t) = X_1(t)X_2(t)$, 则

$$\begin{aligned} d(X_1(t)X_2(t)) &= (\sigma_1(t)X_2(t) + \sigma_2(t)X_1(t))dB(t) \\ &\quad + (b_1(t)X_2(t) + b_2(t)X_1(t) + \sigma_1(t)\sigma_2(t))dt \end{aligned} \quad (7.5.11)$$

对于一般线性 SDE(7.5.6), 设 $(X(t), t \geq 0)$ 满足 (7.5.6), 令 $Y(t) = \rho_{t_0}^{-1}(t)X(t)$, 其中 $\rho_{t_0}(t)$ 由等式 (7.5.10) 定义, 即

$$d\rho_{t_0}(t) = a_1(t)\rho_{t_0}(t)dt + b_1(t)\rho_{t_0}(t)dB(t)$$

令 $f(t, x) = \frac{1}{x}$, 则 $\frac{\partial f}{\partial t} = 0$, $\frac{\partial f}{\partial x} = -\frac{1}{x^2}$, $\frac{\partial^2 f}{\partial x^2} = \frac{2}{x^3}$. 由 Itô 公式可得

$$d\rho_{t_0}^{-1}(t) = [0 - a_1(t)\rho_{t_0}(t)\rho_{t_0}^{-2}(t) + \frac{1}{2}b_1(t)\rho_{t_0}^2(t)2\rho_{t_0}^{-3}(t)]dt + b_1(t)\rho_{t_0}(t)(-\rho_{t_0}^{-2}(t))dB(t)$$

所以

$$\begin{cases} d\rho_{t_0}^{-1}(t) = \rho_{t_0}^{-1}(t)(-a_1(t) + b_1^2(t))dt - b_1(t)\rho_{t_0}^{-1}(t)dB(t) \\ dX(t) = (a_1(t)X(t) + a_2(t))dt + (b_1(t)X(t) + b_2(t))dB(t) \end{cases} \quad (7.5.12)$$

由 (7.5.12) 与 (7.5.11), 可知

$$\begin{aligned} d\rho_{t_0}^{-1}(t)X(t) &= [(a_1(t)X(t) + a_2(t))\rho_{t_0}^{-1}(t) + (-a_1(t) + b_1^2(t))\rho_{t_0}^{-1}(t)X(t) \\ &\quad + (b_1(t)X(t) + b_2(t))(-b_1(t)\rho_{t_0}^{-1}(t))]dt \\ &\quad + [-b_1(t)\rho_{t_0}^{-1}(t)X(t) + b_1(t)X(t) + b_2(t)\rho_{t_0}^{-1}(t)]dB(t) \end{aligned}$$

得

$$d(\rho_{t_0}^{-1}(t)X(t)) = (a_2(t) - b_1(t)b_2(t))\rho_{t_0}^{-1}(t)dt + b_2(t)\rho_{t_0}^{-1}(t)dB(t)$$

对上式两边积分, 并注意到特解 $\rho_{t_0}^{-1}(t_0) = 1$, 有

$$\rho_{t_0}^{-1}(t)X(t) = X(t_0) + \int_{t_0}^t [a_2(s) - b_1(s)b_2(s)]\rho_{t_0}^{-1}(s)ds + \int_{t_0}^t b_2(s)\rho_{t_0}^{-1}(s)dB(s)$$

故

$$X(t) = \rho_{t_0}(t)[X(t_0) + \int_{t_0}^t (a_2(s) - b_1(s)b_2(s))\rho_{t_0}^{-1}(s)ds + \int_{t_0}^t b_2(s)\rho_{t_0}^{-1}(s)dB(s)] \quad (7.5.13)$$

是方程 (7.5.6) 的解, 其中 $\rho_{t_0}(t)$ 由 (7.5.10) 定义, 它是方程 (7.5.7) 的一个基本解.

例 4 设 $\{X(t), t \geq 0\}$ 满足以下 Itô 方程

$$dX(t) = \left(\frac{2}{1+t}X(t) + b(1+t^2)^2\right)dt + b(1+t)^2dB(t) \quad (b > 0 \text{ 为常数}) \quad (7.5.14)$$

则对应的齐次线性方程的基本解为 $\rho_{t_0}(t) = \exp(\int_{t_0}^t \frac{2}{1+u} du) = (\frac{1+t}{1+t_0})^2$. 所以 (7.5.14) 的一般解为

$$\begin{aligned} X(t) &= \left(\frac{1+t}{1+t_0}\right)^2 \left[X(t_0) + \int_{t_0}^t b(1+s)^2 \left(\frac{1+t_0}{1+s}\right)^2 ds + \int_{t_0}^t b(1+s)^2 \left(\frac{1+t_0}{1+s}\right)^2 dB(s)\right] \\ &= \left(\frac{1+t}{1+t_0}\right)^2 [X(t_0) + b(1+t_0)^2(B(t) - B(t_0) + t - t_0)] \\ &= \left(\frac{1+t}{1+t_0}\right)^2 X(t_0) + b(1+t)^2(B(t) - B(t_0) + t - t_0), 0 \leq t_0 \leq t \end{aligned}$$

例 5 C-R-L 电路. 设某 C-R-L 电路上, $Q = Q(t)$ 为 t 时刻的电荷量, 它满足以下微分方程

$$\begin{cases} LQ''(t) + RQ'(t) + \frac{1}{C}Q(t) = U(t) = G(t) + \alpha W(t) \\ Q(0) = Q_0, Q'(0) = I_0 \end{cases} \quad (7.5.15)$$

其中 L, R, C 分别为电感, 电阻与电容, $U(t)$ 为电流电压, 包含两部分, 其一为 $G(t)$, 是 t 的一般函数 (非随机项), 而 α 为常数, $(W(t), t \geq 0)$ 代表白噪声 (随机波动), 有 $W(t) = \frac{dB(t)}{dt}, t \geq 0$, 即 $W(t)$ 是 B.M. 的形式导数.

为求解方程 (7.5.15), 引入向量 $X(t) = (X_1(t), X_2(t))^T = (Q(t), Q'(t))^T$, 则

$$\begin{cases} X_1'(t) = X_2(t) \\ LX_2'(t) = -RX_2(t) - \frac{1}{C}X_1(t) + G(t) + \alpha W(t) \end{cases}$$

向量形式即

$$dX(t) = AX(t) dt + H(t) dt + K dB(t) \quad (7.5.16)$$

其中 $dX(t) = (dX_1(t), dX_2(t))^T$, $\{B(t), t \geq 0\}$ 为一维标准 B.M.

$$A = \begin{bmatrix} 0 & 1 \\ -\frac{1}{CL} & -\frac{R}{L} \end{bmatrix} \quad H(t) = \begin{bmatrix} 0 \\ \frac{1}{L}G(t) \end{bmatrix} \quad K = \begin{bmatrix} 0 \\ \frac{\alpha}{L} \end{bmatrix}$$

(7.5.16) 是一个二维线性 SDE.

对 (7.5.16) 适当移项, 两边同乘以积分因子 e^{-At} , 得

$$e^{-At} dX(t) - Ae^{-At} X(t) dt = e^{-At} [H(t) dt + KB(t)] \quad (7.5.17)$$

其中 $e^{-At} = \sum_{n=0}^{\infty} \frac{(-1)^n}{n!} A^n t^n$. 令

$$g: (0, +\infty) \times R^2 \rightarrow R^2, g(t, x_1, x_2) = \begin{pmatrix} g_1(t, x_1, x_2) \\ g_2(t, x_1, x_2) \end{pmatrix} = e^{-At} \begin{pmatrix} x_1 \\ x_2 \end{pmatrix}$$

(7.5.17) 写成,

$$d(e^{-At} X(t)) = e^{-At} [H(t) dt + KB(t)] \quad (7.5.17a)$$

利用 Itô 公式, 可得 (令 $Y(t) = \frac{1}{X(t)}$)

$$d(e^{-At} X(t)) = (-A)e^{-At} X(t) dt + e^{-At} dX(t)$$

将上式代入 (7.5.17a) 得

$$X(t) = e^{At} [X(0) + e^{-At} KB(t) + \int_0^t e^{-As} [H(s) + AKB(s)] ds] \quad (7.5.18)$$

其中 $X(0) = (Q_0, I_0)^T$.

§ 7.6 解的存在和唯一性问题

前面我们着重讨论了 LSDE 的解的显式表达式. 对于更广泛的一般 SDE, 首先要解决其解的存在唯一性问题, 且通常很难得到它们的显式解. 但是, 研究表明, 保证方程解的存在唯一性条件下, 我们总是可以找到它们的渐近解. 本节给出 SDE 解的存在和唯一性定理及其渐进解.

7.7 解的基本特性与扩散过程

定理 设随机过程 $X = \{X(t), t \geq 0\}$ 满足 Itô 微分方程

$$dX(t) = b(t, X(t)) dt + \sigma(t, X(t)) dB(t) \quad (\forall 0 \leq t \leq T) \quad (7.6.1)$$

或

$$X(t) = X(0) + \int_0^t b(s, X(s)) ds + \int_0^t \sigma(s, X(s)) dB(s) \quad (7.6.2)$$

若 $b(t, x), \sigma(t, x) : [0, T] \times R \rightarrow R$ 满足以下假设条件:

A1(可测性) $b(t, x), \sigma(t, x)$ 二元可测, $|b(t, x)|^{\frac{1}{2}}, \sigma(t, x) \in \mathcal{L}_{[T \times R]}^2$

A2(Lipschitz 条件) 存在常数 $K, s.t.$ 对 $\forall t \in [0, T], \forall x, y \in R$

$$|b(t, x) - b(t, y)| + |\sigma(t, x) - \sigma(t, y)| < K|x - y|$$

A3(线性增长有界条件) 存在常数 $C > 0$

$$|b(t, x)| + |\sigma(t, x)| \leq C(1 + |x|) \quad \forall t \in [0, T], x \in R$$

A4(初始条件) $X(t_0)$ 关于 \mathcal{F}_{t_0} 可测, 且 $EX^2(t_0) < \infty$

则存在唯一的过程 $\{X(t), t \geq 0\}$ 满足 (7.5.1), 且 $X(t)$ 是自适应的, 关于 \mathcal{F}_t 可测, 对 $\forall t \in [0, T], EX^2(t) < \infty$.

(证明从略)

§ 7.7 解的基本特性与扩散过程

在介绍 Itô 随机微分方程解的基本特性之前, 我们先引出扩散过程的概念. 扩散过程在物理学, 生物学, 信息科学, 金融与经济以及社会科学中都有着广泛的应用. 例如描述微小粒子的运动规律, 具有白噪声的信息系统, 完全市场中的股票价格的波动, 生物群体的变化等等, 因此研究扩散过程意义重大.

定义 设连续参数马氏过程 $X = \{X(t), t \geq 0\}$, 状态空间 $S = R$ (或 R^n), 且满足对 $\forall x \in R, t \geq 0, \varepsilon > 0$

$$1^\circ \lim_{h \rightarrow 0} \frac{1}{h} P(|X(t+h) - x| > \varepsilon | X(t) = x) = 0 \quad (7.7.1)$$

$$2^\circ \lim_{h \rightarrow 0} \frac{1}{h} E[(X(t+h) - x) | X(t) = x] = \mu(t, x) < \infty \quad (7.7.2)$$

$$3^\circ \lim_{h \rightarrow 0} \frac{1}{h} E[(X(t+h) - x)^2 | X(t) = x] = \sigma^2(t, x) < \infty \quad (7.7.3)$$

其中 $\mu(t, x), \sigma(t, x)$ 是二元函数, 且 $0 \leq |a(t, x)|, |b(t, x)| < \infty$, 则称 $\{X(t), t \geq 0\}$ 是扩散过程, $\mu(t, x), \sigma(t, x)$ 分别称为扩散过程 $\{X(t), t \geq 0\}$ 的漂移系数与扩散系数.

例 1 漂移 B.M. $\{X(t) = \mu t + \sigma B(t), t \geq 0\}$, 其中 μ, σ 为常数, 它是连续参数马氏过程, 其微分形式为 $dX(t) = \mu dt + \sigma dB(t)$.

易知它满足 1°, 2°, 3°.

$$\lim_{h \rightarrow 0} \frac{1}{h} P\{|X(t+h) - x| > \varepsilon | X(t) = x\} = \lim_{h \rightarrow 0} \frac{1}{h} P\{|\mu h + \sigma(B(t+h) - B(t))| > \varepsilon\} \quad (\text{增量独立})$$

因为 B.M. 均方连续, 即 $B(t+h) \xrightarrow{m.s.} B(t)$ ($h \rightarrow 0$), 故 $|\mu h + \sigma(B(t+h) - B(t))| \xrightarrow{m.s.} 0$, 可得 $|\mu h + \sigma(B(t+h) - B(t))| \xrightarrow{P} 0$, 所以 $\lim_{h \rightarrow 0} \frac{1}{h} P\{|\mu h + \sigma(B(t+h) - B(t))| > \varepsilon\} = 0$, 满足 (7.7.1) 式.

$$\begin{aligned} \lim_{h \rightarrow 0} \frac{1}{h} E[X(t+h) - x | X(t) = x] &= \lim_{h \rightarrow 0} \frac{1}{h} E[\mu h + \sigma(B(t+h) - B(t))] \\ &= \lim_{h \rightarrow 0} \frac{1}{h} [\mu h + \sigma E B(h)] = \mu \end{aligned}$$

满足 (7.7.2) 式.

$$\begin{aligned} \lim_{h \rightarrow 0} \frac{1}{h} E[(X(t+h) - x)^2 | X(t) = x] &= \lim_{h \rightarrow 0} \frac{1}{h} E[\mu h + \sigma(B(t+h) - B(t))]^2 \\ &= \lim_{h \rightarrow 0} \frac{1}{h} [\mu^2 h^2 + 2\mu h \sigma E B(h) + \sigma^2 E(B(t+h) - B(t))^2] \\ &= \sigma^2 \end{aligned}$$

满足 (7.7.3) 式.

因此漂移 B.M. 是扩散运动, 其中 μ 是它的漂移系数, σ 是它的扩散系数. 事实上, μ 是漂移 B.M. $\{X(t), t \geq 0\}$ 在单位时间上的平均漂移, 即过程的系统性漂移, 而 $\sigma^2 t$ 则是过程在 t 时刻的方差. 正是基于这一物理意义, 使它们被称作漂移系数和扩散系数.

例 2 设 $\{X(t), t \geq 0\}$ 满足 Ornstein-Uhlenbeck 方程 (或称之为 Langevin 方程)

$$dX(t) = -\mu X(t) dt + \sigma dB(t) \quad (7.7.4)$$

设 $X(t_0) = X_0 \sim N(0, \sigma_0^2)$, 且与 $\{B(t), t \geq 0\}$ 独立, 其中 μ, σ 为常数, 则其解 $\{X(t), t \geq 0\}$ 是扩散过程.

首先, 由 Itô 随机微分方程求得, 解的显式表达式为

$$X(t) = X_0 e^{-\mu t} + \int_0^t e^{-\mu(t-s)} dB(s)$$

7.7 解的基本特性与扩散过程

由表达式易知 $\{X(t), t \geq 0\}$ 是正态过程, 且 $\forall t \geq 0, EX(t) = 0$,

$$\begin{aligned}
 \forall 0 < s < t, Cov(X(s), X(t)) &= EX(s)X(t) \quad (EX(t) = 0) \\
 &= e^{-\mu(s+t)}\sigma_0^2 + \sigma^2 E\left[\int_0^s \int_0^t e^{-\mu(s-u)} e^{-\mu(t-v)} dB(u)dB(v)\right] \quad (X_0 \text{ 与 } B(t) \text{ 独立}) \\
 &= e^{-\mu(s+t)}\sigma_0^2 + \sigma^2 \int_0^s \int_0^t e^{-\mu(s-u)} e^{-\mu(t-v)} E dB(u) dB(v) \\
 &= e^{-\mu(s+t)}\sigma_0^2 + \sigma^2 e^{-\mu(s+t)} \int_0^s e^{2\mu u} du \\
 &\quad (u \neq v \Rightarrow E dB(u) dB(v) = 0, u = v \Rightarrow E dB(u) dB(v) = du) \\
 &= e^{-\mu(s+t)}\sigma_0^2 + \frac{\sigma^2}{2\mu}(e^{-\mu(t-s)} - e^{-\mu(s+t)})
 \end{aligned}$$

同理 $DX(t) = \sigma_0^2 e^{-2\mu t} + \frac{\sigma^2}{2\mu}(1 - e^{-2\mu t})$

下面证它是马尔可夫过程.

$\forall 0 \leq t_1 < \cdots < t_n < t_{n+1}, x_k \in R, 1 \leq k \leq n$, 则

$$\begin{aligned}
 &E(X(t_{n+1})|X(t_1) = x_1, \cdots, X(t_n) = x_n) \\
 &= E[(e^{-\mu(t_{n+1}-t_n)}X_n + \int_{t_n}^{t_{n+1}} e^{-\mu(t_{n+1}-u)} dB(u))|X(t_1) = x_1, \cdots, X(t_n) = x_n] \\
 &= x_n e^{-\mu(t_{n+1}-t_n)}
 \end{aligned}$$

同理 $E[(X(t_{n+1}) - X(t_n))^2|X(t_1) = x_1, \cdots, X(t_n) = x_n] = \frac{1}{2\mu}(1 - e^{-2\mu(t_{n+1}-t_n)})$.

这就说明, $X(t_{n+1})$ 关于 $X(t_1) = x_1, \cdots, X(t_n) = x_n$ 的条件期望与条件方差仅与 x_n 和 $(t_{n+1} - t_n)$ 有关, 而与 $X(t_1) = x_1, \cdots, X(t_{n-1}) = x_{n-1}$ 无关. 由正态过程的性质, 可得 $X(t_{n+1})$ 关于 $X(t_1), \cdots, X(t_n)$ 的条件概率密度函数是正态概率密度, 为

$$\begin{aligned}
 P(t_1, x_1, t_2, x_2, \cdots, t_n, x_n; t_{n+1}, x) &= P(t_n, x_n; t_{n+1}, x) \\
 &= \frac{1}{\left(\frac{\pi}{\mu}(1 - e^{-2\mu(t_{n+1}-t_n)})\right)^{\frac{1}{2}}} e^{-\frac{(x-x_n e^{-\mu(t_{n+1}-t_n)})^2}{\frac{1}{\mu}[1 - e^{-2\mu(t_{n+1}-t_n)}]}}
 \end{aligned}$$

故 $\{X(t), t \geq 0\}$ 是马尔可夫过程, 其转移概率密度为

$$P(s, x; t, y) = \left(\frac{\mu}{\pi}\right)^{\frac{1}{2}} (1 - e^{-2\mu(t-s)})^{-\frac{1}{2}} e^{-\mu \frac{(y - x e^{-\mu(t-s)})^2}{1 - e^{-2\mu(t-s)}}}.$$

下面来验证 (7.7.1) \sim (7.7.3), 对 $\forall x \in R, t \geq 0, \varepsilon \geq 0$, 求 $\lim_{h \rightarrow 0} \frac{1}{h} P(|X(t+h) - x| > \varepsilon | X(t) = x)$, $\lim_{h \rightarrow 0} \frac{1}{h} E[(X(t+h) - x) | X(t) = x]$, $\lim_{h \rightarrow 0} \frac{1}{h} E[(X(t+h) - x)^2 | X(t) = x]$.

因为由 Chebyshev 不等式和 $\{X(t), t \geq 0\}$ 的性质, 有

$$0 \leq P(|X(t+h) - x| > \varepsilon | X(t) = x) \leq \frac{h^2}{\varepsilon^4}$$

故 $\lim_{h \rightarrow 0} \frac{1}{h} P(|X(t+h) - x| > \varepsilon | X(t) = x) = 0$.

$$\begin{aligned} \lim_{h \rightarrow 0} \frac{1}{h} E[(X(t+h) - x) | X(t) = x] &= \lim_{h \rightarrow 0} \frac{1}{h} [xe^{-\mu h} - x + \int_t^{t+h} e^{-\mu(t+h-u)} du | X(t) = x] \\ &= -\mu x \end{aligned}$$

$$\begin{aligned} &\lim_{h \rightarrow 0} \frac{1}{h} E[(X(t+h) - x)^2 | X(t) = x] \\ &= \lim_{h \rightarrow 0} \frac{1}{h} [\mu^2(e^{-\mu h} - 1)^2 + \sigma^2 E(\int_t^{t+h} e^{-\mu(2t+h)} e^{-2\mu u} du) | X(t) = x] = \sigma^2 \end{aligned}$$

以上便说明了 O-U 过程是漂移系数与扩散系数分别为 μx 与 σ^2 的扩散过程. 而且例 1, 例 2 都表明了扩散过程的系数与 Itô 随机微分方程的系数紧密相连. 那么对于一般的 Itô 过程, 它的解是否有类似的性质呢? 我们有下面的定理:

定理 7.7.1 设 Itô 过程 $\{X(t), t \geq 0\}$ 满足

$$\begin{cases} dX(t) = \mu(t, X(t)) dt + \sigma(t, X(t)) dB(t) \\ X(t_0) = x_0 \end{cases} \quad (7.7.5)$$

其中 $\{B(t), t \geq 0\}$ 是一维标准 B.M. $\mu(t, x), \sigma(t, x), X(t_0)$ 满足假设 A1 ~ A4, 且 $\mu(t, x), \sigma(t, x)$ 是二元连续函数, 则方程存在唯一解 $\{X(t), t \geq 0\}$, 且 $X(t)$ 是扩散过程, 且

$$\begin{aligned} \lim_{h \rightarrow 0} \frac{1}{h} E[(X(t+h) - x) | X(t) = x] &= \mu(t, x) \\ \lim_{h \rightarrow 0} \frac{1}{h} E[(X(t+h) - x)^2 | X(t) = x] &= \sigma^2(t, x). \end{aligned}$$

证明从略.

练习题

7.1 设 $\Omega = [0, 1]$, $\mathcal{F} = \mathcal{B}[0, 1]$, ($\mathcal{B}[0, 1]$ 为一维 Borel σ -域限制在 $[0, 1]$ 上的 σ -域). $\forall A = (a, b) \in \mathcal{F}$, $(a, b) \subset [0, 1]$, $P(A) = b - a$, 令 $X_n(w) = \sqrt{n} \cdot I_{(0 \leq w \leq \frac{1}{n})}$, $n \geq 1$.

(1) $\forall \varepsilon > 0$, 求 $P(X_n \geq \varepsilon)$, 证 $\lim_{n \rightarrow \infty} X_n \stackrel{P}{=} 0$;

(2) 问 $\lim_{n \rightarrow \infty} X_n$ 在均方收敛的意义上是否存在? 说明其理由.

7.2 设 $\{N(t), t \geq 0\}$ 是时齐参数为 λ 的 Poisson 过程. $\forall t \geq 0$, $N(t)$ 是否均方连续? 并证明你的结论.

7.3 设 $(X, Y) \sim N(0, 0, \sigma_1^2, \sigma_2^2, \rho)$. 令 $X(t) \stackrel{261}{=} X + tY$, $Y(t) = \int_0^t X(u) du$, $Z(t) = \int_0^t X^2(u) du$. $\forall 0 \leq s \leq t$

(1) 求 $EX(t), Cov(X(s), X(t))$;

练习题

(2) 求 $EY(t), EZ(t), Cov(Y(s), Y(t)), Cov(Z(s), Z(t))$;

(3) 证 $X(t)$ 在 $t > 0$ 上均方连续, 均方可导;

(4) 求 $Y(t)$ 及 $Z(t)$ 的均方导数;

7.4 (1) 证标准 B.M. $\{B(t), t \geq 0\}$ 均方连续;

(2) 证 $B(t)$, 对 $\forall t > 0$, 几乎对所有轨道, 没有有限导数;

7.5 设 $X \sim N(u, \sigma^2), Y \sim Ge(p)$, 即 $P(Y = k) = (1-p)^{k-1} \cdot p, (0 < p < 1, k = 1, 2, \dots)$.

X 与 Y 独立. 令 $X(t) = X + e^{-t} \cdot Y, Y(t) = \int_0^t X(u) du$

(1) 求 $X(t)$ 在 $t > 0$ 的 p.d.f.;

(2) 求 $EX(t), Cov(X(s), X(t)), (\forall 0 \leq s \leq t)$;

(3) 求 $EY(t), Cov(Y(s), Y(t))$.

7.6 设 $\{X(t), t \geq 0\}$ 的均方导数存在, $EX(t) = 0, R(s, t) = E(X(s), X(t))$, 证

(1) $E(\frac{dX(t)}{dt}) = \frac{dEX(t)}{dt}$;

(2) $E(X(t) \frac{dX(t)}{dt}) = \frac{\partial R(s, t)}{\partial s} |_{s=t}$.

7.7 设 $\{B(t), t \geq 0\}$ 为标准 B.M. $B(t) = 0, \forall t > 0$, 固定取 $0 = t_0 < t_1 < \dots < t_n = t$, $\Delta t_k = t_k - t_{k-1}, \delta_n = \max_{1 \leq k \leq n} \Delta t_k, \Delta B_k = B(t_k) - B(t_{k-1}), B_k = B(t_k)$, 已知 $EB^4(t) = 3t^2$. 证

(1) $\lim_{\delta_n \rightarrow 0} \sum_{k=1}^n \Delta^2 B_k \stackrel{m.s.}{=} t$;

(2) $P(\lim_{\delta_n \rightarrow 0} \sum_{k=1}^n \Delta^2 B_k = t) = 1$;

(3) $P(\lim_{\delta_n \rightarrow 0} \sum_{k=1}^n |\Delta B_k| = \infty) = 1$;

(4) $\lim_{\delta_n \rightarrow 0} \sum_{k=1}^n B_{k-1} \Delta B_k = \frac{B^2(t) - t}{2}; \quad (\text{m.s.})$

(5) $\lim_{\delta_n \rightarrow 0} \sum_{k=1}^n B_k \Delta B_k = \frac{B^2(t) + t}{2}; \quad (\text{m.s.})$

(6) $\lim_{\delta_n \rightarrow 0} [\sum_{k=1}^n B(t_{k-1} + \theta \Delta t_k) (B(t_k) - B(t_{k-1}))] = \frac{B^2(t) + t(1-2\theta)}{2}$, 其中 $\theta \in [0, 1]$ 为

固定.

7.8 设 $\{X(t), t \in R\}$ 是平稳过程且 $EX(t) = 0, R(\tau) = e^{-2|\tau|}$

(1) 证 $\forall t \geq 0$, 均方连续;

(2) 证 $\forall t > 0$, 均方可导;

(3) 记 $Y(t) = \int_0^t X(s) ds$, 求 $EY(t), Cov(Y(s), Y(t))$.

7.9 设 $h(u)$ 是一般的连续函数, $u \geq 0$, 记 $Y(t) = \int_0^t h(s) dB(s), (B(0) = 0)$

(1) 证 $\{Y(t), t \geq 0\}$ 是鞅;

(2) $\forall t \geq 0, \lambda \in R$, 证

$$E[\exp(\lambda \int_0^t h(s) dB(s))] = \exp(\frac{\lambda^2}{2} \int_0^t h^2(s) ds).$$

7.10 $h(u)$ 同题 7.9, 且是有界变差函数, 证明

$$\int_0^t h(s) dB(s) = h(t)B(t) - \int_0^t B(s) dh(s).$$

7.11 用 Itô 积分定义证 $\int_0^t s dB(s) = tB(t) - \int_0^t B(s) ds$. (提示: $\sum_k \Delta(s_k B_k) = \sum_k s_k \Delta B_k + \sum_k B_k \Delta s_k$)

7.12 用 Itô 积分定义证

- (1) $\int_0^t B(s) dB(s) = \frac{B^2(t)-t}{2}$ (提示: $\Delta(B_k^2) = B_k^2 - B_{k-1}^2 = \Delta^2 B_k + 2B_{k-1}(\Delta B_k)$, $B^2(t) = \sum_k \Delta(B_k^2) = \sum_k \Delta^2 B_k + 2 \sum_k B_{k-1} \Delta B_k$);
- (2) $\int_0^t B^2(s) dB(s) = \frac{B^3(t)}{3} - \int_0^t B(s) ds$.

7.13 设 $\{X_k(t), t \geq 0\}$ 满足 $dX_k(t) = b_k(t) dt + \sigma_k(t) dB(t)$, $1 \leq k \leq 2$, 其中 b_k, σ_k 满足 Itô 公式的条件, 证 $d(X_1(t)X_2(t)) = X_1(t) dX_2(t) + X_2(t) dX_1(t) + dX_1(t) \cdot dX_2(t)$.

7.14 利用 Itô 公式, 求以下诸过程所满足的 Itô 随机微分方程:

- (1) $X(t) = B^3(t)$;
 (2) $X(t) = \alpha + t + e^{B(t)}$;
 (3) $X(t) = e^{ut + \alpha B(t)}$;
 (4) $X(t) = e^{\frac{t}{2}} \cos B(t)$.

7.15 求下列 Itô 随机微分方程的特解 (若给出初始条件) 或一般解, $t \geq 0$

- (1) $dX(t) = uX(t) dt + \sigma dB(t)$, ($u, \sigma > 0$ 为常数), (Ornstein-Uhlenbeck 方程);
 $X(0) \sim N(0, \sigma^2)$, 且与 $\{B(t), t \geq 0\}$ 独立.

- (2) $dX(t) = -X(t) dt + e^{-t} dB(t)$;
 (3) $dX(t) = \gamma dt + \alpha X(t) dB(t)$, (γ, α 为常数);
 (4) $dX(t) = (m - X(t)) dt + \sigma dB(t)$, ($m, \sigma > 0$ 为常数);
 (5) $dX(t) = (e^{-t} + X(t)) dt + \sigma X(t) dB(t)$, ($\sigma > 0$ 为常数).

7.16 设 $V(t) = e^{-\alpha t} B(e^{2\alpha t})$, ($\alpha > 0$ 为常数), $\forall t > 0$.

- (1) 求 $\lim_{h \rightarrow 0} \frac{1}{h} E[(V(t+h) - V(t))|V(t)]$;
 (2) 求 $\lim_{h \rightarrow 0} \frac{1}{h} E[(V(t+h) - V(t))^2|V(t)]$.

7.17 设 $\{X(t), t \in R\}$ 满足 Itô 方程. $dX(t) = b(t)X(t) dt + \sigma(t) dB(t)$, (其中 $b(t), \sigma(t)$ 为 t 的连续函数)

- (1) 求 $\lim_{h \rightarrow 0} \frac{1}{h} E[(X(t+h) - X(t))|X(t)]$;
 (2) 求 $\lim_{h \rightarrow 0} \frac{1}{h} E[(X(t+h) - X(t))^2|X(t)]$.

7.18 设 $\{B(t), t \in (-\infty, +\infty)\}$ 为标准 B.M. 二阶矩过程 $\{X(t), t \in (-\infty, +\infty)\}$ 满足 Itô 方程: $dX(t) = -\alpha X(t) + dB(t)$, $X(-\infty) = 0$, $\alpha > 0$

- (1) $\forall s, t \geq 0$, 求 $X(s+t)$ 在 $X(s) = x$ 下的条件 p.d.f.;
 (2) $\forall 0 < t_1 < t_2 < \cdots < t_n < t_{n+1}$, 求 $X(t_{n+1})$ 在 $X(t_k) = x_k, (1 \leq k \leq n)$ 下的条件 p.d.f.;
 (3) 试问 $\{X(t), t \in (-\infty, +\infty)\}$ 是否是平稳过程? 马氏过程? 鞅? 证明你的结论.

7.19 设 $\{X(t), t \in (-\infty, +\infty)\}$ 同题 7.18, $\{Y(t), t \in (-\infty, +\infty)\}$ 满足方程: $dY(t) = -\beta Y(t) dt + dX(t)$, $\beta > 0$

练习题

(1) $\forall s, t \geq 0$, 求 $Y(s+t)$ 在 $Y(s) = y$ 下的条件 p.d.f.;

(2) $\forall t > 0$, 求 $\lim_{h \rightarrow 0} \frac{1}{h} E[(Y(t+h) - Y(t)) | Y(t)]$, $\lim_{h \rightarrow 0} \frac{1}{h} E[(Y(t+h) - Y(t))^2 | Y(t)]$.

7.20 设 $X = \{X(t), t \geq 0\}$ 是满足题 7.15(1) 的特解.

(1) 试问 X 是否是马氏过程? 试证明你的结论;

(2) 若 $X = \{X(t), t \geq 0\}$ 是 M.P., 试求它的转移概率密度函数 $f(s, x; t, y)$, 即 $f(s, x; t, y)$ 满足: 对 $\forall 0 \leq s < t, x, y \in R, B \in \mathcal{B}$, 有: $P(X(s+t) \in B | X(s) = x) = \int_{y \in B} f(s, x; t, y) dy$.

第八章 宽平稳过程

所谓平稳过程, 粗略地说, 就是指它的概率特性不随时间推移而变化的随机过程. 这类过程在工程技术中比较常见, 本章着重介绍其中的宽平稳过程.

以下各节中, 我们设 $X_T = \{X(t), t \in T\}$ 为随机过程, 并且记 $m(t) = EX(t)$, $D(t) = DX(t)$, $R(s, t) = Cov(X(s), X(t))$, $\rho(s, t) = \frac{R(s, t)}{\sqrt{D(s)D(t)}}$.

§ 8.1 宽平稳过程的定义与举例

定义 设随机过程 $X_T = \{X(t), t \in T\}$, $E|X(t)|^2 < \infty$, (即 X_T 为二阶矩过程). 若 $EX(t) = m$ 为常数, $Cov(X(t), X(s)) = E[(X(t) - m)(\overline{X(s) - m})] = R(t - s)$, 则称 X_T 为 **宽平稳过程**, 或 **协方差平稳过程**.

当 $T = Z = \{0, \pm 1, \pm 2, \dots\}$ 时, 称 X_T 为 **平稳序列**.

下面举一些宽平稳过程 (序列) 的例子.

例 1 (1) 设 $\xi = \{\xi_n, n \in Z\}$ 为实的 (或复的) 随机序列, 且 $E\xi_n = 0$, $E|\xi_n|^2 = \sigma^2 < \infty$, $E\xi_n \xi_m = \delta_{nm} \cdot \sigma^2$ 其中

$$\delta_{nm} = \begin{cases} 1 & n = m \\ 0 & n \neq m \end{cases}$$

可见 $\xi = \{\xi_n, n \in Z\}$ 是宽平稳过程, 人们常称 $\xi = \{\xi_n, n \in Z\}$ 为白噪声, .

(2) 设 $X_n = \sum_{k=-\infty}^{+\infty} a_k \xi_{n-k}$, 其中 $\{\xi_n, n \in Z\}$ 为白噪声, $\sum_{k=-\infty}^{+\infty} |a_k|^2 < \infty$. 为了说明 X_n 是宽平稳过程, 我们先来证明 $\sum_{k=-\infty}^{+\infty} a_k \xi_{n-k}$ 是有意义的.

令 $X_n^N = \sum_{k=-N}^N a_k \xi_{n-k}$, 则对 $\forall n, (X_n^N, N \geq 0)$ 均方收敛, 记 $\sum_{k=-\infty}^{+\infty} a_k \xi_{n-k} \stackrel{m.s.}{=} \lim_{N \rightarrow \infty} X_n^N$ 有意义. 这是因为 $\forall n \in Z$ 固定, 当 $N > M$ 时

$$E|X_n^N - X_n^M|^2 = E \left| \sum_{M \leq |k| \leq N} a_k \xi_{n-k} \right|^2 = \sigma^2 \sum_{M \leq |k| \leq N} |a_k|^2 \xrightarrow{N, M \rightarrow \infty} 0$$

即 $\{X_n^N, N \geq 0\}$ 关于 N 是 Cauchy 序列, 所以 $\exists X_n \stackrel{m.s.}{=} \lim_{N \rightarrow \infty} X_n^N = \sum_{k=-\infty}^{\infty} a_k \xi_{n-k}$. 现在来考察 X_n 的概率特征: 显然 $EX_n = 0$,

$$\begin{aligned} R(n, n+r) &= E(X_n \overline{X_{n+r}}) = E \left[\left(\sum_{k=-\infty}^{\infty} a_k \xi_{n-k} \right) \overline{\left(\sum_{l=-\infty}^{\infty} a_l \xi_{n+1-l} \right)} \right] \\ &= \left(\sum_{k=-\infty}^{\infty} a_k \overline{a_{k+r}} \right) \sigma^2 \triangleq \frac{R(r)}{265} \end{aligned}$$

上式只与时间差 r 有关. 所以 $X_T = \{X_n, n \in Z\}$ 为宽平稳过程 (序列).

8.1 宽平稳过程的定义与举例

例 2 随机简谐运动的叠加

(1) $X_n = \xi \cos nw + \eta \sin nw$, $n \in Z$, 其中 $w \in [0, \pi]$ 为角频率. $E\xi = E\eta = 0$, $E\xi^2 = E\eta^2 = \sigma^2$, 且 $E(\xi\eta) = 0$, 即 ξ, η 互不相关. 称 X_n 为随机简谐运动. 显然 $EX_n = 0$

$$\begin{aligned} R(n, n+r) &= E(X_n \overline{X_{n+r}}) = E[(\xi \cos nw + \eta \sin nw)(\xi \cos(n+r)w + \eta \sin(n+r)w)] \\ &= \sigma^2 (\cos(n+r)w \cos nw + \sin(n+r)w \sin nw) \\ &= \sigma^2 \cos rw \triangleq R(r) \end{aligned}$$

上式只与时间差 r 有关, 所以 X_n 是宽平稳过程.

(2) $X_n = \sum_{k=0}^m (\xi_k \cos nw_k + \eta_k \sin nw_k)$, $n \in Z$, 其中 $w_k \in [0, \pi]$, 为角频率. $E\xi_k = E\eta_k = 0$, $E\xi_k^2 = E\eta_k^2 = \sigma_k^2$, $E(\xi_k \xi_l) = E(\eta_k \eta_l) = 0$ ($k \neq l$), $\forall 0 \leq k, l \leq m$, $E(\xi_k \eta_l) = 0$. 于是可得 $EX_n = 0$,

$$\begin{aligned} R(n, n+r) &= E(X_n \overline{X_{n+r}}) \\ &= E\left[\sum_{k=0}^m (\xi_k \cos nw_k + \eta_k \sin nw_k) \sum_{l=0}^m (\xi_l \cos(n+l)w_l + \eta_l \sin(n+l)w_l)\right] \\ &= \sum_{k=0}^m \sigma_k^2 [\cos(n+r)w_k \cos nw_k + \sin(n+r)w_k \sin nw_k] \\ &= \sum_{k=0}^m \sigma_k^2 \cos rw_k \end{aligned}$$

上式只与 r 有关, 所以 X_n 为宽平稳过程.

(3) $X_n = \sum_{k=0}^{\infty} \xi_k e^{inw_k}$, 其中 ξ_k 性质同上, 且 $\sum_{k=0}^{\infty} \sigma_k^2 < \infty$, $n \in Z$, 则由 $X_n = \sum_{k=0}^{\infty} \xi_k (\cos nw_k + i \sin nw_k)$, 可得 $EX_n = 0$.

$$R(n+r, n) = E(X_{n+r} \overline{X_n}) = E\left(\sum_{k=0}^{\infty} \xi_k e^{i(n+r)w_k} \sum_{l=0}^{\infty} \xi_l e^{-inw_l}\right) = \sum_{k=0}^{\infty} \sigma_k^2 e^{irw_k} \triangleq R(r)$$

上式仅与 r 有关. 所以复随机序列 X_n 为宽平稳过程.

若令 $\sigma^2 = \sum_{k=0}^{\infty} \sigma_k^2$, $p_k = \frac{\sigma_k^2}{\sigma^2}$, $\forall \omega \in [0, \pi]$ 记 $F(\omega) = \sum_{k: \omega_k \leq \omega} p_k$, 易知, $F(\omega)$ 是 $[0, \pi]$ 上的单调不减, 右连续的台阶形函数, $F(0) = 0, F(\pi) = 1$. 即 $F(\omega)$ 是 $[0, \pi]$ 上的一分布函数. 它是刻画不同频率电流分量的分配. 通常称 $F(\omega)$ 为电流 X_n 的功率谱函数 (详见本章第四节). 则相关系数

$$\rho(r) = \frac{R(r)}{R(0)} = \sum_{k=0}^{\infty} p_k e^{irw_k} = \sum_{k=0}^{\infty} p_k (\cos rw_k + i \sin rw_k) = \sum_{k=0}^{\infty} p_k e^{irw_k} = \int_0^{\pi} e^{ir\omega} dF(\omega).$$

即 $\rho(r)$ 可看作是 $F(\omega)$ 的富利埃变换.

266

这说明, 当角频率不同对应的随机振幅互不相关的可列 (或有限) 个随机简谐运动的叠加是一平稳序列.

这样, 如果将 X_n 看作是 n 时刻电流, 那么它可以看作是由不同角频率 w_k 电流分量按 w_k 对应的 ξ_k 为随机振幅叠加而成. 则 p_k 表示电流在不同频率上的功率分配.

推而广之, 是否任意的平稳随机序列都可以得到如上述相关函数类似的分解呢? 或者说, 是否它们都对应一个如 $\rho(r)$ 的功率谱函数呢? 这个问题我们将在后面第四节中回答.

宽平稳过程的基本特征, 是协方差函数只与时间差有关, 并不随时间推移而改变. 因此在宽平稳过程中, 协方差函数非常重要. 下面我们就介绍协方差函数的几个基本性质. 设 $R(s, t)$ 是 $\{X(t), t \in T\}$ 的协方差函数, $m(t)$ 是其均值函数.

1° 实随机过程的协方差函数是对称的; 复随机过程的协方差函数是共轭反对称的. 即当 $X(t)$ 是实的, $R(s, t) = R(t, s)$; 当 $X(t)$ 是复的, $R(s, t) = \overline{R(t, s)}$.

证 由定义 $R(s, t) = Cov(X(s), X(t)) = E[(X(s) - m(s))(X(t) - m(t))]$, 易得上述结论.

2° 协方差函数是非负定的. 即对 $\forall n \geq 1, \forall \tau_1, \tau_2, \dots, \tau_n \in T, \forall z_1, \dots, z_n \in C$ 有 $\sum_{k=1}^n \sum_{j=1}^n R(\tau_k, \tau_j) z_k \bar{z}_j \geq 0$.

证 由定义

$$\begin{aligned} \sum_{k=1}^n \sum_{j=1}^n R(\tau_k, \tau_j) z_k \bar{z}_j &= \sum_{k=1}^n \sum_{j=1}^n E[(X(\tau_k) - m(\tau_k))(\overline{X(\tau_j) - m(\tau_j)})] z_k \bar{z}_j \\ &= E\left[\sum_{k=1}^n (X(\tau_k) - m(\tau_k)) z_k \overline{\sum_{j=1}^n (X(\tau_j) - m(\tau_j)) z_j}\right] \\ &= E\left[\left|\sum_{k=1}^n (X(\tau_k) - m(\tau_k)) z_k\right|^2\right] \geq 0 \end{aligned}$$

3° 宽平稳过程的协方差函数 $R(s, t) = R(s - t)$. 它具有以下性质:

- 1) $R(0) = D(t)$ (由定义易得)
- 2) $|R(z)| \leq R(0)$ (由 schwartz 不等式易得)
- 3) $R(z) = \overline{R(-z)}$

因此实平稳过程的协方差函数是偶函数.

§ 8.2 正态过程

1. 正态过程

正态过程在工程技术与管理中有广泛的应用, 同时它也是随机过程中一个重要的分支. 一方面, 它是二阶矩过程的代表和典型, 另一方面它在理论上又具有许多良好的性质, 特别是它的概率特性仅由它的均值函数与协方差函数唯一决定. 本节将进一步讨论它的几个特性. 为此, 我们先回顾 n 维正态随机向量的定义, 然后, 进一步推广.

8.2 正态过程

定义 设 $X = (X_k, 1 \leq k \leq n)^T$ 是 n 维随机向量, 我们称它是 n 维正态随机向量, 若它的概率密度函数为:

$$f(x) = (2\pi)^{-\frac{n}{2}} |\Sigma|^{-\frac{1}{2}} \exp\left[-\frac{1}{2}(x - \mu)^T \Sigma^{-1}(x - \mu)\right] \quad (8.2.1)$$

其中 $x = (x_k, 1 \leq k \leq n)^T \in R^n$, $\mu = (\mu_k, 1 \leq k \leq n)^T, 1 \leq k \leq n$, Σ 是 n 阶正定对称矩阵. 此时记作 $X \sim N(\mu, \Sigma)$.

易知, $EX_k = \mu_k, 1 \leq k \leq n, \Sigma$ 是 X 的协方差矩阵, 即: $\Sigma = E(X - \mu)(X - \mu)^T$, 且 $X \sim N(\mu, \Sigma)$ 的特征函数为 $\varphi(t) \triangleq Ee^{it^T X} = \exp(i\mu^T t - \frac{1}{2}t^T \Sigma t)$, 其中 $t = (t_k, 1 \leq k \leq n)^T \in R^n$. 证明可见参考书 [6].

在 (8.2.1) 中, 要求 Σ 是正定对称阵, 以保证 Σ^{-1} 存在, 否则该表达式没有意义. 可用特征函数推广多维正态分布.

定义 $\varphi(t) = \exp(i\mu^T t - \frac{1}{2}t^T \Sigma t)$ 是 d 维随机向量 $X = (X_k, 1 \leq k \leq d)$ 的特征函数, 其中 $t \in R^d, \mu \in R^d, \Sigma$ 是 d 阶非负定对称矩阵, 则称 X 为 d 维正态分布随机向量, 记为 $X \sim N(\mu, \Sigma)$.

注意, 此时对 $\det \Sigma = |\Sigma| = 0$ 的情形仍有意义. 但其 p.d.f. 无法表示, 可以证明若 $\text{rank} \Sigma = r$ ($r < d$), 则其 p.d.f. 集中在一个 r 维子空间上, 这时称为退化正态分布.

引理 8.2.1 若 d 维随机向量 $X^{(n)}, X$ 特征函数分别为 $\varphi_n(t), \varphi(t)$, 且 $\lim_{n \rightarrow \infty} X^{(n)} \stackrel{m.s.}{\rightarrow} X$, 则对 $\forall t \geq 0, \varphi_n(t) \rightarrow \varphi(t)$

证 仅证当 $X^{(n)}$ 与 X 都是一维随机变量的情形.

$\forall t \geq 0$ 固定, 因为 $|e^{itX^{(n)}} - e^{itX}| \leq |X^{(n)} - X|$, 则 $|\varphi_n(t) - \varphi(t)|^2 \leq \|e^{itX^{(n)}} - e^{itX}\|^2 \leq \|X^{(n)} - X\|$, 得 $\lim_{n \rightarrow \infty} \varphi_n(t) = \varphi(t)$. 当 $X^{(n)}$ 与 X 为多维的, 类似可证.

对于正态随机序列, 它们具有以下性质:

命题 8.2.1 若 $X^{(n)} = (X_k^{(n)}, 1 \leq k \leq d)$ 为 d 维正态随机向量, 且 $X^{(n)}$ 均方收敛于 $X = (X_k, 1 \leq k \leq d)$, 即对 $\forall 1 \leq k \leq d, \|X_k^{(n)} - X_k\|^2 = E|X_k^{(n)} - X_k|^2 \rightarrow 0 (n \rightarrow \infty)$, 则 $X = (X_k, 1 \leq k \leq d)$ 也是 d 维正态随机向量.

证 记 $EX^{(n)} = \mu^{(n)} = (\mu_k^{(n)}, 1 \leq k \leq d)^T, EX = \mu = (\mu_k, 1 \leq k \leq d), \Sigma^{(n)} = E(X^{(n)} - \mu^{(n)})(X^{(n)} - \mu^{(n)})^T = (\sigma_{ij}^{(n)}), \Sigma = E(X - \mu)(X - \mu)^T = (\sigma_{ij})$.

则由 $X_k^{(n)} \stackrel{m.s.}{\rightarrow} X_k, 1 \leq k \leq d$, 有

$$\lim_{n \rightarrow \infty} \mu_k^{(n)} = \mu_k \quad 1 \leq k \leq d \quad (8.2.2)$$

及

$$\lim_{n \rightarrow \infty} \sigma_{kj}^{(n)} = \sigma_{kj} \quad 1 \leq k \leq d, 1 \leq j \leq d \quad (8.2.3)$$

则由 $X^{(n)}$ 为 d 维正态随机变量, 有

$$\varphi_n(t) = \exp(it^T \mu^{(n)} - \frac{1}{2}t^T \Sigma^{(n)} t)$$

由 (8.2.2) 及 (8.2.3) 得 $\lim_{n \rightarrow \infty} \varphi_n(t) = \exp(it^T \mu - \frac{1}{2}t^T \Sigma t)$. 由引理 8.2.1, 有 X 的特征函数 $\varphi(t) = \lim_{n \rightarrow \infty} \varphi_n(t) = \exp(it^T \mu - \frac{1}{2}t^T \Sigma t)$.

所以 X 也是 d 维正态随机向量.

命题 8.2.2 设 $X_T = \{X(t), t \in T\}$ 为均方可导 (可微) 的正态过程, 则均方导数过程 $\{X'(t), t \in T\}$ 也是正态过程.

证: 由正态随机向量对线性变换的封闭性和定理 8.2.1 知, 若 X'_T 存在, 则 $\{X'(t_k) = \lim_{h \rightarrow 0} \frac{X(t_k+h) - X(t_k)}{h}, 1 \leq k \leq d\}$ 是正态过程.

命题 8.2.3 设 $X_T = \{X(t), t \in T\}$ 为均方可积的正态过程, 令 $Y(t) = \int_a^t X(u)du, (a, t \in T)$, 则 $\{Y(t), t \in T\}$ 也是正态过程.

证: 对 $\forall t_k \in T$, 由均方可积的定义知:

$$Y(t_k) \stackrel{m.s.}{=} \sum_{l=1}^n X(s_l) \Delta s_l.$$

其中 $a = s_0 < s_1 < \cdots < s_n = t_k$. 由正态过程对线性组合的封闭性和定理 8.2.1 得 $\{Y(t), t \in T\}$ 是正态过程.

引理 8.2.2 设 (实) 二阶矩过程 $X_T = \{X(t), t \in T\}$ 是平稳过程且均方可微, 则 $\forall t \in T$ 有:

$$E(X(t) \cdot X'(t)) = 0$$

证: 由 X_T 是平稳过程 (实), 则 $R(\tau) = R(-\tau)$, 故 $\rho(\tau) = \rho(-\tau)$, 又因为 X_T 均方可微, 所以 $R(s, t) = R(s - t) = \text{Cov}(X(s), X(t))$ 广义二次可导, 故 $\rho(\tau) = \frac{R(\tau)}{R(0)}$ 存在二阶导数, 因此 $\rho'(\tau) = -\rho'(-\tau)$, 令 $\tau = 0$, 则 $R'(0) = -R'(0)$, 故: $R'(0) = 0$. 由第七章命题 7.1.2 有:

$$\begin{aligned} E(X(s) \cdot X'(t)) &= \lim_{h \rightarrow 0} E[X(s) \cdot \frac{X(t+h) - X(t)}{h}] \\ &= \lim_{h \rightarrow 0} \frac{R(s, t+h) - R(s, t)}{h} \\ &= \frac{\partial}{\partial t} R(s, t) \end{aligned}$$

由此知:

$$E(X(t) \cdot X'(t)) = R'(0) = 0.$$

由引理 8.2.2 很容易推导出正态过程的以下性质:

命题 8.2.4 设 $X_T = \{X(t), t \in T\}$ 是平稳正态过程且均方可导 (可微), 则 $\forall t \in T, X(t)$ 与 $X'(t)$ 相互独立, 且若 $R(s, t) = R(s - t)$ 是 X_T 的协方差, 则:

$$DX'(t) = \frac{\partial^2}{\partial s \partial t} R(s, t)|_{s=t} = -R''(0).$$

基于正态过程独立与不相关的等价性, 我们可以得到正态过程和马氏过程之间的联系.

8.2 正态过程

2. 马尔可夫正态过程

定义 设马尔可夫过程 $X_T = \{X(t), t \geq 0\}$ 又是正态过程, 则称 X_T 为马尔可夫正态过程.

为讨论马尔可夫正态过程的重要性质, 先给出 n 维正态分布的条件 p.d.f. 设 $X = \{X_1, X_2, \dots, X_n\}$ 是 n 维正态过程, 其联合概率密度为:

$$f(x_1, \dots, x_n) = ((2\pi)^{-n/2} A^{-n/2}) \exp\left[-\frac{1}{2} \sum_{i=1}^n \sum_{j=1}^n a_{ij} x_i x_j\right]$$

其中 $A^{-1} = (a_{ij})$ 为对称正定矩阵. 现考虑 X_n 在给定 $X_1 = x_1, \dots, X_{n-1} = x_{n-1}$ 下的条件 p.d.f. 记为 $f(x_n | x_1, \dots, x_{n-1})$. 它等于:

$$\frac{f(x_1, \dots, x_n)}{\int_{-\infty}^{+\infty} f(x_1, \dots, x_n) dx_n} = \frac{\exp\left[-\frac{1}{2} \sum_{i=1}^n \sum_{j=1}^n a_{ij} x_i x_j\right]}{\int_{-\infty}^{+\infty} \exp\left[-\frac{1}{2} \sum_{i=1}^n \sum_{j=1}^n a_{ij} x_i x_j\right] dx_n} \quad (*)$$

由 $\sum_{i=1}^n \sum_{j=1}^n a_{ij} x_i x_j = \sum_{i=1}^{n-1} \sum_{j=1}^{n-1} a_{ij} x_i x_j + a_{nn} x_n^2 + 2x_n \cdot \sum_{i=1}^{n-1} a_{in} x_i$, 从 (*) 式的分子分母中消去与 x_n 无关的因子后, 我们有:

$$\begin{aligned} f(x_n | x_1, \dots, x_{n-1}) &= \frac{\exp\left(-\frac{1}{2} a_{nn} x_n^2 - x_n \cdot \sum_{i=1}^{n-1} a_{in} x_i\right)}{\int_{-\infty}^{+\infty} \exp\left(-\frac{1}{2} a_{nn} x_n^2 - x_n \cdot \sum_{i=1}^{n-1} a_{in} x_i\right) dx_n} \\ &= \frac{\exp\left\{-\frac{1}{2} a_{nn} \left[x_n + \sum_{i=1}^{n-1} (a_{in}/a_{nn}) x_i\right]^2\right\}}{\int_{-\infty}^{+\infty} \exp\left\{-\frac{1}{2} a_{nn} \left[x_n + \sum_{i=1}^{n-1} (a_{in}/a_{nn}) x_i\right]^2\right\} dx_n} \\ &= c \cdot \exp\left\{-\frac{1}{2} a_{nn} \left[x_n + \sum_{i=1}^{n-1} \frac{a_{in}}{a_{nn}} x_i\right]^2\right\} \quad (8.2.4) \end{aligned}$$

其中 c 为规一化的常数, 与 (x_1, \dots, x_{n-1}) 无关, (8.2.4) 式是一正态 p.d.f. 其均值为 $-\sum_{i=1}^{n-1} (a_{in}/a_{nn}) x_i$. 于是:

$$E(X_n | X_1 = x_1, \dots, X_{n-1} = x_{n-1}) = -\sum_{i=1}^{n-1} \frac{a_{in}}{a_{nn}} x_i, \quad (8.2.5)$$

$$E(X_n | X_{n-1} = x_{n-1}) = -\frac{a_{n-1,n}}{a_{nn}} x_{n-1}. \quad (8.2.5a)$$

设 $\{X(t), t \geq 0\}$ 为正态过程, 不失一般性设 $EX(t) = 0$. 记 $R(s, t) = E(X(s)X(t))$, $\rho(s, t) = R(s, t)/(R(s, s)R(t, t))^{\frac{1}{2}}$.

命题 8.2.5 设 $\{X(t), t \geq 0\}$ 是正态过程, $EX(t) = 0$, 则它也是马尔可夫过程的充要条件是: $\forall 0 \leq t_1 < t_2 < \dots < t_n, n \geq 2$,

$$E\{X_{t_n} | X_{t_1} = x_1, \dots, X_{t_{n-1}} = x_{n-1}\} = E\{X_{t_n} | X_{t_{n-1}} = x_{n-1}\}. \quad (8.2.6)$$

证: 必要性显然. 为证充分性, 注意到 (8.2.5) 及 (8.2.5a) 可得: $a_{1n} = a_{2n} = \dots = a_{n-2,n} = 0$. 故由 (8.2.4) 有: 270

$$f(x_n | x_1, \dots, x_{n-1}) = c \cdot \exp\left\{-\frac{1}{2} a_{nn} \left[x_n + \frac{a_{n-1,n}}{a_{nn}} x_{n-1}\right]^2\right\}$$

与

$$f(x_n|x_{n-1}) = c \cdot \exp\left\{-\frac{1}{2}a_{nn}\left[x_n + \frac{a_{n-1,n}}{a_{nn}}x_{n-1}\right]^2\right\}$$

故而充分性得证.

命题 8.2.6 设 $\{X(t), t \geq 0\}$ 是正态过程, $EX(t) = 0$, 则它也是马尔可夫过程的充要条件是: $\forall 0 \leq t_1 < t_2 < t_3$,

$$\rho(t_1, t_3) = \rho(t_1, t_2)\rho(t_2, t_3). \quad (8.2.7)$$

证: \Rightarrow , 设 $X(t)$ 是马尔可夫过程, 则由 (8.2.5) 式得对任意 $0 < s < t$,

$$E(X(t)|X(s) = x) = -\left(\frac{a_{n-1,n}}{a_{nn}}\right)x. \quad (8.2.8)$$

为求 $(a_{n-1,n}/a_{nn})$ 考虑 $(X(s), X(t))$ 的 j.p.d.f.

$$f_{s,t}(x_1, x_2) = (2\pi)^{-1}|A^{-1}|^{1/2} \exp\left(-\frac{1}{2}x^T A x\right),$$

其中

$$A^{-1} = \begin{bmatrix} R(s, s) & R(s, t) \\ R(t, s) & R(t, t) \end{bmatrix}^{-1} = \frac{1}{R(s, s)R(t, t) - R(s, t)^2} \begin{bmatrix} R(t, t) & -R(t, s) \\ -R(s, t) & R(s, s) \end{bmatrix}$$

由上及 (8.2.8) 式得:

$$E(X(t)|X(s) = x) = \left(\frac{R(s, t)}{R(s, s)}\right)x. \quad (8.2.9)$$

再由马氏性,

$$R(t_1, t_3) = E(X(t_1)X(t_3)) = E\{E[X(t_1)X(t_3)|X(t_2)]\} = E\{E[X(t_1)|X(t_2)]E[X(t_3)|X(t_2)]\}$$

由 (8.2.9) 式得:

$$R(t_1, t_3) = E\left\{\frac{R(t_1, t_2)}{R(t_2, t_2)}X(t_2)\frac{R(t_2, t_3)}{R(t_2, t_2)}X(t_2)\right\} = \frac{R(t_1, t_2)R(t_2, t_3)}{R(t_2, t_2)}.$$

由上式可得 (8.2.7) 式.

\Leftarrow , 由 (8.2.7) 式, 可得: 对 $\forall 1 \leq k \leq n-1$.

$$\rho(t_k, t_n) = \rho(t_k, t_{n-1})\rho(t_{n-1}, t_n).$$

即:

$$R(t_k, t_n) = \frac{R(t_k, t_{n-1})R(t_{n-1}, t_n)}{R(t_{n-1}, t_{n-1})}.$$

8.2 正态过程

从而对 $\forall 0 \leq k \leq n-1$,

$$E \left\{ \left[X(t_n) - \frac{R(t_{n-1}, t_n)}{R(t_{n-1}, t_{n-1})} X(t_{n-1}) \right] X(t_k) \right\} = 0,$$

这就意味着正态 r.v. $X(t_n) - \frac{R(t_{n-1}, t_n)}{R(t_{n-1}, t_{n-1})} X(t_{n-1})$ 与 $X(t_1), \dots, X(t_{n-1})$ 相互独立, 故:

$$E \left\{ X(t_n) - \frac{R(t_{n-1}, t_n)}{R(t_{n-1}, t_{n-1})} X(t_{n-1}) \mid X(t_1) = x_1, \dots, X(t_{n-1}) = x_{n-1} \right\} = 0.$$

即:

$$E\{X(t_n) \mid X(t_1) = x_1, \dots, X(t_{n-1}) = x_{n-1}\} = \frac{R(t_{n-1}, t_n)}{R(t_{n-1}, t_{n-1})} x_{n-1} = E\{X(t_n) \mid X(t_{n-1}) = x_{n-1}\}.$$

3. 平稳正态过程

平稳正态过程是平稳过程中的一个重要代表. 这里给出它的一些主要特性.

设 $\{X(t), t \in T\}$ 为实正态过程. 不失一般性, 设 $EX(t) = 0, R(s, t) = E(X(s)X(t))$.

有如下的:

命题 8.2.7 一实正态过程 $\{X(t), t \geq 0\}$ 是严平稳过程的充要条件是: $\forall 0 \leq s < t$, 有:

$$R(s, t) = R(t - s). \quad (8.2.10)$$

证: 设 $\{X(t), t \geq 0\}$ 是严平稳过程, 则 $\forall s, t \geq 0$ 及 τ , 有

$$R(s, t) = E(X(s)X(t)) = E(X(s + \tau)X(t + \tau)) = R(s + \tau, t + \tau).$$

上式中取 $\tau = -s$ 得 $R(s, t) = R(0, t - s) \triangleq R(t - s)$.

反之, 若 $R(s, t) = R(t - s)$, 则 $\forall 0 \leq t_1 < t_2 < \dots < t_n, (X(t_1), \dots, X(t_n))$ 的特征函数为:

$$\varphi(u_1, \dots, u_n) = \exp\left\{-\frac{1}{2} \sum_{i=1}^n \sum_{j=1}^n u_i u_j R(t_i - t_j)\right\}$$

而这也是 $(X(t_1 + \tau), \dots, X(t_n + \tau))$ 的特征函数. 故 $\{X(t), t \geq 0\}$ 为严平稳过程.

推论 宽平稳正态过程也是严平稳过程.

什么时候一个平稳正态过程也是马尔可夫过程? Doob 给出了这个问题的回答.

命题 8.2.8 一个均方连续的平稳正态过程 $\{X(t), t \geq 0\}, EX(t) = 0$. 也是马尔可夫过程的充要条件是相关函数:

$$\rho(\tau) = e^{-\mu|\tau|}. \quad (8.2.11)$$

其中 $\mu > 0$ 为常数.

证: 因 $\{X(t), t \geq 0\}$ 均方连续, 且是正态过程, 则由命题 (8.2.7) 有:

$$R(s + t) = R(s)R(t). \quad (8.2.12)$$

即 $\rho(s+t) = \rho(s)\rho(t)$, 且 $\rho(t)$ 在 $\rho(0)$ 连续. 但 $\rho(0) = 1$, 可得 $\rho(t+h) - \rho(t) = \rho(t)(\rho(h) - 1) \rightarrow 0$, 当 $h \rightarrow 0$ 时. 得 $\rho(t)$ 对 $\forall t \in R$ 均方连续. 又由 (8.2.12) 式得方程 $\rho(s+t) = \rho(s)\rho(t)$, 知 $\rho(\tau) = e^{-\mu\tau}$ 其中 $\mu > 0$ 为常数. 又 $\rho(\tau) = \rho(-\tau)$. 得: $\rho(\tau) = e^{-\mu|\tau|}$.

反之, 若 $\rho(\tau) = e^{-\mu|\tau|}$, 则可得 $\rho(s, t) = \rho(t-s), \rho(s+t) = \rho(s)\rho(t)$. 于是 $\forall 0 \leq t_1 < t_2 < t_3$, 有 $\rho(t_3 - t_1) = \rho(t_2 - t_1)\rho(t_3 - t_2)$, 即: $\rho(t_1, t_3) = \rho(t_1, t_2)\rho(t_2, t_3)$. 由命题 8.2.6 可得 $\{X(t), t \geq 0\}$ 为马尔可夫过程.

§ 8.3 ARMA 过程

所谓 ARMA 过程, 即 Autoregressive Moving Average Process, 亦即自回归滑动和过程, 其数学定义如下:

定义 设 $\{\xi_n, n \in Z\}$ 为白噪声序列, 若 $\{X_n, n \in Z\}$ 是满足下列方程的平稳过程:

$$\sum_{k=0}^p a_k X_{n-k} = \sum_{l=0}^q b_l \xi_{n-l}. \quad (8.3.1)$$

其中 $a_0 = 1, a_k, b_l, 0 \leq k \leq p, 0 \leq l \leq q$ 均为常数, 且 $\alpha(z) \triangleq \sum_{k=0}^p a_k z^k$ 与 $\beta(z) \triangleq \sum_{l=0}^q b_l z^l$ 的根都在单位圆外. 则称 $\{X_n, n \in Z\}$ 为 ARMA 过程 (或 ARMA 模型).

ARMA 模型在工程技术, 自动控制等领域具有重要意义. 我们仍然由简入繁来讨论 ARMA 模型的性质.

1. 一阶自回归模型 AR(1)

以下讨论均假设 $\{\xi_n, n \in Z\}$ 为白噪声, 即 $E\xi_n = 0, E\xi_n \xi_m = \delta_{nm} \cdot \sigma^2$

设 $\{X_n, n \in Z\}$ 是二阶矩过程, 若它是满足下列方程的平稳序列

$$\begin{cases} X_n - aX_{n-1} = \xi_n & |a| < 1 \\ X_{-\infty} = 0 \end{cases} \quad (8.3.2)$$

则称它为 AR(1) 模型.

(1) 先看 $X_0 = 0$ 时的情形:


此时有 $X_n = \sum_{k=0}^{n-1} a^k \xi_{n-k} + a^n X_0 = \sum_{k=0}^{n-1} a^k \xi_{n-k}$, 且对于 $r \geq 0$:

$$\begin{aligned} E(X_n X_{n+r}) &= E \left[\sum_{k=0}^{n-1} a^k \xi_{n-k} \cdot \sum_{l=0}^{n+r-1} a^l \xi_{n+r-l} \right] \\ &= E \left[\sum_{k=0}^{n-1} \sum_{l=0}^{n+r-1} a^k a^l \xi_{n-k} \xi_{n+r-l} \right] \\ &= \sigma^2 \cdot \sum_{k=0}^{n-1} (a^k a^{k+r}) = \sigma^2 a^r \cdot \frac{1 - a^{2n}}{1 - a^2}. \end{aligned}$$

8.3 ARMA 过程

(2) 当 $X_{-\infty} = 0$ 时, 有 $X_n = \sum_{k=0}^{\infty} a^k \xi_{n-k}$, 类似于 (1) 可得到 $E(X_n X_{n+r}) = \sigma^2 a^r \cdot \frac{1}{1-a^2}, (r \geq 0)$. 即当 $r \geq 0$ 时, $R(r) = \frac{a^r \sigma^2}{1-a^2}$. 而 $R(0) = \frac{\sigma^2}{1-a^2}$, 故 $\rho(r) = a^{|r|}$. 一般的当 $r \in Z$ 时, $\rho(r) = a^{|r|}$.

于是可以得到 $\rho(r)$ 的图如下:



因为差分方程 $X_n - aX_{n-1} = 0$ 的一般解是 $\bar{X}_n = ca^n$ (c 为常数). 显然对于 (8.3.2), 它有一般解 $\hat{X}_n = ca^n + \sum_{k=0}^{\infty} a^k \xi_{n-k}$ (c 为常数). 则当 $|a|$ 使 X_n 均方有意义 (即 $|a| < 1$) 时, (8.3.2) 一定存在一个特解是平稳解. 即: $X_n = \sum_{k=0}^{\infty} a^k \xi_{n-k}$.

注 X_n 可由 n 时刻 (包括 n 时刻) 之前的噪声 ξ_n, ξ_{n-1}, \dots , 的线性组合表示. 故 $\forall k \geq 1$ $cov(\xi_{n+k}, X_n) = 0$, 即 $\xi_{n+k} \perp X_n, \forall n \in Z, k \geq 1$.

2. 高阶自回归模型 $AP(p) (p \geq 2)$

$$\sum_{k=0}^p a_k X_{n-k} = \xi_n.$$

例当 $p = 2$ 时, $AR(2)$ 模型为满足下述条件的平稳序列 $\{X_n, n \in Z\}$:

$$X_n + a_1 X_{n-1} + a_2 X_{n-2} = \xi_n. \quad (8.3.3)$$

其中 a_1, a_2 是常数. 令 $\alpha(z) = 1 + a_1 z + a_2 z^2$ 是方程 (8.3.3) 的系数多项式, 且 $f(z) = z^2 + a_1 z + a_2 = (z - u_1)(z - u_2)$ 满足 $|u_i| < 1$ (不妨设 $u_1 \neq u_2$).

为了进一步研究方便, 我们引进向后推移算子 (Backward Operator) B , 即 $BX_n \triangleq X_{n-1}, B^2 X_n = B(BX_n) = X_{n-2}, \dots, B^k X_n = B(B^{k-1} X_n) = X_{n-k}, \dots$, 设 B^{-1} 是 B 的逆, 记 $B^{-1}B = I$, 有: $B^{-1}(BX_n) = IX_n = X_n, B^{-1}X_n = X_{n+1}$.

设多项式 $\alpha(z) = \sum_{k=0}^p a_k z^k$, 则它相应的 B 算子多项式为:

$$\alpha(B) = \sum_{k=0}^p a_k B^k$$

规定 $\alpha(B)X_n \triangleq \sum_{k=0}^p a_k X_{n-k}$. 将 $\alpha(B)$ 的逆记为 $\alpha(B)^{-1} \triangleq \frac{1}{\alpha(B)}$, 不失一般性, 以下均假定 $X_{-\infty} = 0$. 这样 $\lim_{k \rightarrow \infty} B^k X_n = \lim_{k \rightarrow \infty} X_{n-k} = X_{-\infty} = 0$, 故可约定 $\lim_{k \rightarrow \infty} B^k = 0$ (算子: $0X_n = 0$). 这时算子多项式的运算规则与通常多项式的运算一样, 如: 由 $\alpha(z) = 1 + a_1 z + a_2 z^2 = (1 - u_1 z)(1 - u_2 z)$ 可得 $\alpha(B) = I + a_1 B + a_2 B^2 = (I - u_1 B)(I - u_2 B)$.

此外, 还可得到: $(I - B^{n+1}) = (I - B)(\sum_{k=0}^n B^k)$, 令 $n \rightarrow \infty$ 则 $I = (I - B)(\sum_{k=0}^{\infty} B^k)$ 即:

$$(I - B)^{-1} \triangleq \frac{1}{I - B} = \sum_{k=0}^{\infty} B^k.$$

同理: $(I - aB)^{-1} = \sum_{k=0}^{\infty} a^k B^k, |a| < 1$.

这样我们就可以利用 B 算子解方程 (8.3.2). 由 $X_n - aX_{n-1} = \xi_n$, 有: $(I - aB)X_n = \xi_n$, 故

$$X_n = \frac{1}{I - aB} \xi_n = (\sum_{k=0}^{\infty} a^k B^k) \xi_n = \sum_{k=0}^{\infty} a^k \xi_{n-k}.$$

当 $|a| < 1$ 时, X_n 有意义. 利用 B 算子求解方程 (8.3.2), 其简便性一目了然.

以下, 我们利用 B 算子求解 (8.3.3).

(8.3.3) 所示差分方程的解的结构与一般差分方程类似, 即它的一般解是其对应齐次方程

$$X_n + a_1 X_{n-1} + a_2 X_{n-2} = 0 \quad (8.3.3a)$$

的一般解加上 (8.3.3) 的一个特解.

由 $f(z) = (z - u_1)(z - u_2)$ 易得 (8.3.3a) 的一般解为: $c_1 u_1^n + c_2 u_2^n$. 而 (8.3.3) 的一个特解可借助于 B 算子求出.

由 $\alpha(z) = 1 + a_1 z + a_2 z^2 = (1 - u_1 z)(1 - u_2 z)$ 可知 $\alpha(B) = I + a_1 B + a_2 B^2 = (I - u_1 B)(I - u_2 B)$. 则 (8.3.3) 可写成: $\alpha(B)X_n = \xi_n$, 故: $X_n = \alpha^{-1}(B)\xi_n$. 而:

$$\alpha^{-1}(B) = \frac{1}{\alpha(B)} = \frac{1}{(I - u_1 B)(I - u_2 B)} = \frac{1}{u_1 - u_2} \left(\frac{u_1}{I - u_1 B} - \frac{u_2}{I - u_2 B} \right)$$

因此

$$X_n = \frac{1}{u_1 - u_2} \left(\frac{u_1}{I - u_1 B} - \frac{u_2}{I - u_2 B} \right) \xi_n = \frac{1}{u_1 - u_2} \sum_{k=0}^{\infty} (u_1^{k+1} - u_2^{k+1}) \xi_{n-k} \quad (8.3.4)$$

当 $|u_i| < 1, i = 1, 2$ 时, $c_1 u_1^n + c_2 u_2^n \xrightarrow{n \rightarrow \infty} 0$. 若取 $c_1 = c_2 = 0$ 易验证由 (8.3.3) 式表示的过程 $X_T = \{X_n, n \in Z\}$ 是平稳过程. 因此称 $X_n = \frac{1}{u_1 - u_2} \sum_{k=0}^{\infty} (u_1^{k+1} - u_2^{k+1}) \xi_{n-k}$ 是方程 (8.3.3) 的平稳解.

由 (8.3.4) 式可知, X_n 可表为 n 时刻 (包括 n 时刻) 之前的噪声 ξ_n, ξ_{n-1}, \dots , 的线性组合表示. 故 $\forall k \geq 1 \text{ cov}(\xi_{n+k}, X_n) = 0$, 即 $\xi_{n+k} \perp X_n, \forall n \in Z, k \geq 1$.

下面我们来看一看 X_n 的概率特性, 求 X_T 的相关函数 $\rho(r)$. 注意到 $E\xi_n X_n = \sigma^2$. 在方程 (8.3.3) 的两边同乘以 X_n , 然后取数学期望, 则有:

$$\rho(0) + a_1 \rho(1) + a_2 \rho(2) = \frac{\sigma^2}{\sigma_X^2}$$

同理, 在方程 (8.3.3) 的两边同乘以 $X_{n-r}, (r \geq 1)$, 然后取期望, 则:

$$\rho(r) + a_1 \rho(r-1) + a_2 \rho(r-2) = 0 \quad (8.3.5)$$

8.3 ARMA 过程

显然, (8.3.5) 式的一般解为: $\rho(r) = e_1 u_1^r + e_2 u_2^r$.

当 $r = 0$ 时, $\rho(0) = 1$, 则 $e_1 + e_2 = 1$, (8.3.6a)

当 $r = 1$ 时, $\rho(1) + a_1 \rho(0) + a_2 \rho(1) = 0 \Rightarrow \rho(1) = \frac{-a_1}{1+a_2} = \frac{u_1+u_2}{1+u_1 u_2}$, 故:

$$e_1 u_1 + e_2 u_2 = \frac{u_1 + u_2}{1 + u_1 u_2}. \quad (8.3.6b)$$

由 (8.3.6a) 与 (8.3.6b) 可解得:

$$e_1 = \frac{(1 - u_2^2)u_1}{(u_1 - u_2)(1 + u_1 u_2)} \quad e_2 = \frac{(1 - u_1^2)u_2}{(u_1 - u_2)(1 + u_1 u_2)}$$

所以

$$\rho(r) = \frac{1}{(u_1 - u_2)(1 + u_1 u_2)} [(1 - u_2^2)u_1^{r+1} - (1 - u_1^2)u_2^{r+1}] \quad (r \geq 0)$$

当 $r < 0$ 时, $\rho(r) = \rho(-r)$.

注: 当 $u_1 = u_2 = u$ 时, 易知 (8.3.3a) 的一般解为 $c_1 n u^n + c_2 u^n$.

类似的, 对于 $\text{AR}(p): \{X_n, n \in Z\}$ 是满足方程:

$$X_n + a_1 X_{n-1} + \cdots + a_p X_{n-p} = \xi_n \quad (8.3.7)$$

的平稳解. 系数多项式为: $\alpha(z) = 1 + a_1 z + a_2 z^2 + \cdots + a_p z^p, f(z) = z^p + a_1 z^{p-1} + \cdots + a_{p-1} z + a_p$. 设 $f(z)$ 的 p 个根为 $u_i, 1 \leq i \leq p, |u_i| < 1$ (且不妨设两两不相等), 则相应的 B 算子多项式为 $\alpha(B) = I + a_1 B + a_2 B^2 + \cdots + a_p B^p = (I - u_1 B) \cdots (I - u_p B)$, 于是 (8.3.7) 式化为 $\alpha(B)X_n = \xi_n$, 故 $X_n = \frac{1}{\alpha(B)}\xi_n$ 将 $\alpha^{-1}(B)$ 写成最简的一次分式和的形式, 可有:

$$\alpha^{-1}(B) = \sum_{i=1}^p \frac{d_i}{(I - u_i B)}.$$

则:

$$X_n = \left[\sum_{i=1}^p \frac{d_i}{(I - u_i B)} \right] \xi_n = \sum_{i=1}^p [d_i (\sum_{l=0}^{\infty} u_i^l) \xi_{n-l}].$$

也就是说 $\text{AR}(p)$ 中的 X_n 是 $\{\xi_n, n \in Z\}$ 在 n 时刻及之前的噪声的线性组合, 故: $\forall k \geq 1$ $\text{cov}(\xi_{n+k}, X_n) = 0$, 即 $\xi_{n+k} \perp X_n, \forall n \in Z, k \geq 1$.

与求 $\text{AR}(2)$ 的相关系数类似, 可得:

$$\sigma_X^2 = \sigma^2 / [\rho(0) + a_1 \rho(1) + \cdots + a_p \rho(p)], \quad (8.3.8)$$

$$\rho(r) + a_1 \rho(r-1) + \cdots + a_p \rho(r-p) = 0. \quad (r \geq 1) \quad (8.3.9)$$

(8.3.9) 的一般解为:

$$\rho(r) = e_1 u_1^r + e_2 u_2^r + \cdots + e_p u_p^r. \quad (8.3.10)$$

而为了确定待定系数 (e_1, \dots, e_p) 可由下列条件:

$$\begin{cases} \rho(0) = 1 \\ \rho(1) + a_1\rho(0) + \dots + a_p\rho(p-1) = 0 \\ \rho(2) + a_1\rho(1) + \dots + a_p\rho(p-2) = 0 \\ \dots\dots\dots \\ \rho(p-1) + a_1\rho(p-2) + \dots + a_p\rho(1) = 0 \end{cases}$$

求出 $\rho(0), \dots, \rho(p-1)$, 代入 (8.3.10) 即可得

$$\begin{cases} e_1 + e_2 + \dots + e_p = 1 \\ e_1u_1 + e_2u_2 + \dots + e_pu_p = \rho(1) \\ e_1u_2^2 + e_2u_2^2 + \dots + e_pu_p^2 = \rho(2) \\ \dots\dots\dots \\ e_1u_1^{p-1} + e_2u_2^{p-1} + \dots + e_pu_p^{p-1} = \rho(p-1) \end{cases} \quad (8.3.11)$$

解上述方程组即可求得 (e_1, \dots, e_p) , 从而求出形如 (8.3.10) 的 $\rho(r)$.

3. 平均滑动和模型 MA(q)

设二阶矩过程 $\{X_n, n \in Z\}$ 满足:

$$X_n = b_0\xi_n + b_1\xi_{n-1} + \dots + b_q\xi_{n-q}. \quad (8.3.12)$$

其中 b_0, \dots, b_q 为常数, 则 (8.3.12) 的平稳解称为 q 阶平均滑动和模型.

令 $\beta(B) = \sum_{l=0}^q b_l B^l$, 则 $X_n = \beta(B)\xi_n$, 得 $\xi_n = \beta^{-1}(B)X_n$. 即 ξ_n 可由 X_n, X_{n-1}, \dots 的线性组合表示.

显然, 当 $|r| > q$ 时, $R(r) = 0, \rho(r) = 0$; 当 $|r| \leq q$ 时, 不妨先设 $0 < r \leq q$, 则有:

$$R(r) = E(X_n X_{n+r}) = E\left[\left(\sum_{k=0}^q b_k \xi_{n-k}\right)\left(\sum_{j=0}^q b_j \xi_{n+r-j}\right)\right] = \sum_{k=0}^{q-r} b_k b_{k+r} = \sum_{k=r}^q b_k b_{k-r}.$$

得:

$$\rho(r) = \begin{cases} 0 & |r| > q \\ \sum_{k=|r|}^q b_k b_{k-|r|} / \sum_{k=0}^q b_k^2 & |r| \leq q \end{cases}$$

4. 自回归滑动和模型 (过程), ARMA(p, q)

设二阶矩过程 $\{X_n, n \in Z\}$ 满足:

$$X_n + a_1 X_{n-1} + \dots + a_p X_{n-p} = b_0 \xi_n + b_1 \xi_{n-1} + \dots + b_q \xi_{n-q}. \quad (8.3.13)$$

则上述方程的平稳解称为 ARMA(p, q).

令 $\alpha(z) = \sum_{k=1}^p a_k z^k, (a_0 = 0), \beta(z) = \sum_{l=0}^q b_l z^l$. 则 (8.3.13) 的算子表示式为:
 $\alpha(B)X_n = \beta(B)\xi_n$, 故, $X_n = \alpha^{-1}(B)\beta(B)\xi_n$.

8.3 ARMA 过程

设 $\alpha(z)$ 在 $|z| < 1$ 为解析的, 即 $\alpha(z)$ 的根在单位圆外, 则 (8.3.13) 式有平稳解. 当 $r \geq \max(p, q+1)$ 时, 可得:

$$\rho(r) + a_1\rho(r-1) + \cdots + a_p\rho(r-p) = 0. \quad (8.3.14)$$

上式的一般解为:

$$\rho(r) = e_1 u_1^r + \cdots + e_p u_p^r. \quad (8.3.15)$$

在 (8.3.13) 的两边分别乘以 $\xi_{n-r} (0 \leq r \leq p)$ 可求出 $E(X_n \xi_{n-r})$; 在 (8.3.13) 的两边分别乘以 $X_{n-r} (0 \leq r \leq p)$ 可求出 $\rho(1), \cdots, \rho(p-1)$ 及 $\rho(0) = 1$. 把它们代入 (8.3.15) 即可求出待定系数 (e_1, \cdots, e_p) .

5. 一般线性过程 (The General Linear Processes)

定义 若平稳过程 $\{X_n, n \in Z\}$ 满足:

$$X_n = \sum_{k=0}^{\infty} g_k \xi_{n-k}. \quad (8.3.16)$$

其中

$$\sum_{k=0}^{\infty} g_k^2 < +\infty. \quad (8.3.17a)$$

$$G(z) = \sum_{k=0}^{\infty} g_k z^k. \quad (8.3.17b)$$

在 $|z| < 1$ 上解析, 则称 X_n 是一般线性过程.

上述定义中, (8.3.17a) 保证了 X_n 的存在性, (8.3.17b) 保证了 X_n 是平稳的. 类似于 MA(q), 可得 X_n 的相关系数:

$$\rho(r) = \frac{\sum_{k=0}^{\infty} g_k g_{r-k}}{\sum_{k=0}^{\infty} g_k^2}$$

显然, 当 $g_k = a^k, (|a| < 1)$ 时, (8.3.16) 化为 AR(1) 模型;

当 $g_k = \frac{1}{u_1 - u_2} (u_1^{k+1} - u_2^{k+1}) (u_1 \neq u_2, |u_i| < 1)$ 时, (8.3.16) 化为 AR(2) 模型;

当 $g_k = \begin{cases} b_k & (0 \leq k \leq q) \\ 0 & (k > q) \end{cases}$ 时, (8.3.16) 化为 MA(q) 模型.

因此, $\{g_k, k \geq 0\}$ 刻划了系统的基本特性, 它又被称为格林响应函数 (Green's Function).

6. 连续参数 AR(p) 模型

这里只讨论一阶与二阶的简单模型.

(1) 连续参数 AR(1): 设二阶矩过程 $X(t), t \in R$ 是满足下列方程的平稳解,

$$X'(t) + aX(t) = \frac{dB(t)}{dt}. \quad (8.3.18)$$

其中: $a > 0, (B(t), t \in R)$ 是标准 B.M., $\{\frac{dB(t)}{dt}, t \in R\}$ 是其形式导数. 则 $\{X(t), t \in R\}$ 是连续参数 AR(1) 过程.

由第七章可知: $dX(t) + aX(t)dt = dB(t)$ 的平稳解是: $X(t) = \int_{-\infty}^t e^{-a(t-u)}dB(u)$. 与之比较, 我们引入微分算子 D , 即 $DX(t) = X'(t)$, 则 (8.3.18) 可化为:

$$(D + aI)X(t) = \frac{dB(t)}{dt}$$

由此可得:

$$X(t) = \frac{1}{D + aI} \frac{dB(t)}{dt} = \int_{-\infty}^t e^{-a(t-u)}dB(u).$$

(2) 连续参数 AR(2): $\{X(t), t \in R\}$ 是二阶矩过程, 且是满足下列方程的平稳解:

$$X''(t) + a_1X'(t) + a_2X(t) = \frac{dB(t)}{dt}. \quad (8.3.19)$$

设 $\alpha(z) = z^2 + a_1z + a_2 = (z + u_1)(z + u_2)$, $u_1 \neq u_2, u_i > 0$, 则 $\alpha(D) = (D + u_1I)(D + u_2I)$, 故:

$$\alpha^{-1}(D) = \frac{1}{(D + u_1I)(D + u_2I)} = \frac{1}{u_2 - u_1} \left(\frac{1}{(D + u_1I)} - \frac{1}{(D + u_2I)} \right)$$

类似于 (1), 利用 D 算子, 可得 (8.3.19) 的平稳解为:

$$X(t) = \frac{1}{u_2 - u_1} \int_{-\infty}^t (e^{-u_1(t-u)} - e^{-u_2(t-u)})dB(u).$$

§ 8.4 平稳过程的谱分解和协方差函数 (相关函数) 的谱分解

在第一节中所举出的例 2(3) 中我们看到, 一个由不同角频率的随机振幅互不相关的随机简谐运动的叠加构成的随机序列是宽平稳过程. 那么是否任一个宽平稳过程 (或序列) 都可以分解为由角频率互不相同, 相应的随机振幅互不相关的随机简谐运动的线性叠加呢? 其协方差函数是否也可以写成 § 8.1 中例 2(3) 的协方差函数的类似形式呢? 答案是肯定的.

为了从直观上理解随机过程谱分解的意义, 我们先介绍正交增量过程及关于正交增量过程的均方积分的概念.

1. 正交增量过程

定义 称随机过程 $\{\xi(\lambda), \lambda \in (-\infty, +\infty)\}$ 为正交增量过程, 若它满足:

$$1) \forall \lambda_1 < \lambda_2, E(\xi(\lambda_2) - \xi(\lambda_1)) = 0$$

2) $\forall \lambda_1 < \lambda_2 \leq \lambda_3 < \lambda_4, E\{(\xi(\lambda_2) - \xi(\lambda_1))(\overline{\xi(\lambda_3) - \xi(\lambda_4)})\} = 0$ (即不重叠区间上的增量相互正交 (不相关)).

$$3) \{\xi(\lambda), \lambda \in (-\infty, +\infty)\} \text{ 均方右连续, 即: } \lim_{h \rightarrow 0+} \xi(\lambda + h) = \xi(\lambda), \quad (m.s.)$$

8.4 平稳过程的谱分解和协方差函数 (相关函数) 的谱分解

以下我们均假定 $\xi(-\infty) = 0, E|\xi(+\infty)|^2 < \infty$.

记 $G(\lambda) = E|\xi(\lambda)|^2$, 由 $\xi(\lambda)$ 均方右连续可知 $G(\lambda)$ 右连续. 又 $\forall \lambda_1 < \lambda_2, E(\xi(\lambda_2)\overline{\xi(\lambda_1)}) = E[(\xi(\lambda_2) - \xi(\lambda_1) + \xi(\lambda_1))\overline{\xi(\lambda_1)}] = E|\xi(\lambda_1)|^2 = G(\lambda_1)$, 故 $G(\lambda_2) = E|\xi(\lambda_2)|^2 = E|\xi(\lambda_2) - \xi(\lambda_1) + \xi(\lambda_1)|^2 \geq G(\lambda_1)$. 即 $G(\lambda)$ 为单调不减函数.

若记 $F(\lambda) = G(\lambda)/G(+\infty)$, 则 $0 = F(-\infty) \leq F(\lambda) \leq F(+\infty) = 1$, 且 $F(\lambda)$ 也为单调不减右连续函数. 故 $F(\lambda)$ 可以看作是一个定义在 $(-\infty, +\infty)$ 上的分布函数. 显然, 独立增量过程都是正交增量过程, 如 Poisson 过程, B.M. 等.

与 Itô 积分有些类似, 我们可以定义一种关于正交增量过程的 $R-S$ 积分.

设 $f(\lambda, t)$ 是 (λ, t) 的二元函数, $\lambda \in (-\infty, +\infty), t \in T, \forall [a, b] \subset (-\infty, +\infty)$ 及 $a = \lambda_0 < \lambda_1 < \dots < \lambda_{k-1} < \lambda_k < \dots < \lambda_n = b$, 任取 $u_k \in [\lambda_{k-1}, \lambda_k]$, 记 $\Delta\lambda_k = \lambda_k - \lambda_{k-1}, \delta = \max_k \Delta\lambda_k, \Delta\xi_k = \xi(\lambda_k) - \xi(\lambda_{k-1})$. 若

$$\lim_{\delta \rightarrow 0} \sum_{k=1}^n f(u_k) \Delta\xi_k = I_{[a,b]}(f) \quad (m.s.)$$

存在, 则称 $I_{[a,b]}(f)$ 为 $f(x)$ 关于 $\{\xi(\lambda), \lambda \in (-\infty, +\infty)\}$ 在 $[a, b]$ 上的 $R-S$ 均方积分, 记作 $I_{[a,b]}(f) = \int_a^b f(\lambda) d\xi(\lambda)$. 同样, 记广义积分 $\int_{-\infty}^{+\infty} f(\lambda) d\xi(\lambda) \stackrel{m.s.}{=} \lim_{a \rightarrow -\infty, b \rightarrow +\infty} \int_a^b f(\lambda) d\xi(\lambda)$.

若取 $f(\lambda, t) = e^{i\lambda t}, (i = \sqrt{-1})$, 则 $\int_a^b e^{i\lambda t} d\xi(\lambda)$ 可看作是角频率不同, 对应的随机振幅不相关的简谐运动的叠加, 其中每一个分量为 $e^{itu_k} \Delta\xi_k = (\cos u_k t + i \sin u_k t) \Delta\xi_k$.

注: $\int_a^b e^{i\lambda t} d\xi(\lambda) \triangleq \int_a^b \cos \lambda t d\xi(\lambda) + i \int_a^b \sin \lambda t d\xi(\lambda)$.

若令 $X(t) = \int_{-\infty}^{+\infty} e^{it\lambda} d\xi(\lambda)$, 则 $\{X(t), t \in (-\infty, +\infty)\}$ 在 t 时刻的状态 $X(t)$ 是由角频率不同, 对应的随机振幅不相关的随机简谐运动叠加而成. 下面我们来证明这样的过程必是宽平稳过程.

显然 $EX(t) = 0$, 对 $\forall \lambda_1 \neq \lambda_2$ (不妨设 $\lambda_1 < \lambda_2$), 一定可以取到充分小的 $h_1, h_2 > 0$, s.t. $\lambda_1 < \lambda_1 + h_1 < \lambda_2 < \lambda_2 + h_2$. 记 $\Delta\xi(\lambda_i) = \xi(\lambda_i + h_i) - \xi(\lambda_i), i = 1, 2$, 则 $\Delta\xi(\lambda_i)$ 互不相关, 即 $E(\Delta\xi(\lambda_1)\overline{\Delta\xi(\lambda_2)}) = 0$, 于是由 Fubini 定理有

$$R(t+\tau, t) = E(X(t+\tau)\overline{X(t)}) = \int_{-\infty}^{+\infty} \int_{-\infty}^{+\infty} e^{i(t+\tau)\lambda_1} e^{-it\lambda_2} E(d\xi(\lambda_1)\overline{d\xi(\lambda_2)})$$

因, 当 $\lambda_1 = \lambda_2$ 时, $E(d\xi(\lambda_1)\overline{d\xi(\lambda_2)}) = dG(\lambda_1)$, 当 $\lambda_1 \neq \lambda_2$ 时, $E(d\xi(\lambda_1)\overline{d\xi(\lambda_2)}) = 0$ 故 $R(t+\tau, t) = \int_{-\infty}^{+\infty} e^{i\tau\lambda} dG(\lambda)$ 仅与 τ 有关, 所以 $\{X(t), t \in (-\infty, +\infty)\}$ 是宽平稳过程.

记 $R(\tau) = R(t+\tau, t) = \int_{-\infty}^{+\infty} e^{i\tau\lambda} dG(\lambda)$, 则 $R(0) = G(+\infty)$. 因此, 分布函数 $F(\lambda) = G(\lambda)/G(+\infty)$ 的物理意义有如下解释: 若 $\Delta\xi(\lambda)$ 是角频率为 λ 的电流 (或电压), 则 $G(+\infty) = E|\xi(+\infty)|^2$ 表示信号平均总功率. $dF(\lambda) = dG(\lambda)/G(+\infty)$ 表示角频率为 λ 的电流 (或电压) 信号的平均功率在总功率中所占的比例. 于是, 通常我们把 $F(\lambda)$ 或 $G(\lambda)$ 称为功率谱函数 (功率谱分布), 用它表示不同角频率信号的平均功率的分布.

同样的, $\rho(\tau) = R(\tau)/R(0) = \int_{-\infty}^{+\infty} e^{i\tau\lambda} dF(\lambda)$ (或 $R(\tau) = \int_{-\infty}^{+\infty} e^{i\tau\lambda} dG(\lambda)$) 表示了相关函数 (或协方差函数) 的功率谱分解.

以上我们证明了由角频率不同, 对应的随机振幅不相关的随机简谐运动叠加而成的随机过程一定是宽平稳的. 那么反过来是否成立呢? 即是否所有平稳过程及其相关函数都可以作这样的谱分解呢? 以下的内容将说明这种谱分解是平稳过程的共性.

2. 相关函数 (或协方差函数) 的谱分解

相关函数之所以能够进行谱分解, 是因为它具有非负定性. 为了说明这一点, 我们先引述数学分析中的两个定理.

定理 8.4.1 Bochner- Khintchine 定理

设 $R(\tau)$ 是 $\tau \in (-\infty, +\infty)$ 的连续函数, 则它是非负定函数的充要条件是存在一个分布函数 $F(\lambda)(\lambda \in (-\infty, +\infty), F(-\infty) = 0, F(+\infty) = 1)$, 对 $\forall \tau \in R$ 满足 $\frac{R(\tau)}{R(0)} = \int_{-\infty}^{+\infty} e^{i\tau\lambda} dF(\lambda)$. 而且这种表示式是唯一的.

对于离散的情形, 有类似的结果, 表述如下:

定理 8.4.2 Herglotz's 定理

设 $\{C_n, n \in Z\}$ 是一个序列, 它是非负定的序列的充要条件是存在一个分布函数 $F(\lambda)(\lambda \in (-\pi, +\pi), F(-\pi) = 0, F(+\pi) = 1)$, 对 $\forall n \in Z$ 满足 $\frac{C_n}{C_0} = \int_{-\pi}^{+\pi} e^{in\lambda} dF(\lambda)$.

以上两定理的证明从略, 有兴趣的读者可参看 [5,20].

在第一节中, 我们已经说过相关函数 $\rho(\cdot)$ 是非负定的, 因此, 我们有以下定理:

定理 8.4.3 设 $\rho(r)$ 为平稳序列 $\{X_n, n \in Z\}$ 的相关函数, 则有如下表示:

$$\rho(r) = \int_{-\pi}^{+\pi} e^{ir\lambda} dF(\lambda) \quad (8.4.1)$$

其中 $F(\lambda)$ 是 $[-\pi, \pi]$ 上的分布函数, 称 $F(\lambda)$ 为 $\rho(r)$ 的功率谱函数.

若 X_n 为实 r.v., 则:

$$\rho(r) = 2 \int_0^{\pi} \cos r\lambda dF(\lambda) \quad (8.4.2)$$

若 $\rho(r)$ 满足: $\sum_{r \in Z} |\rho(r)| < \infty$, 则 $F'(\lambda) = f(\lambda)$ 存在, 且:

$$f(\lambda) = \frac{1}{2\pi} \sum_{r=-\infty}^{+\infty} \rho(r) e^{-i\lambda r} \quad (8.4.3)$$

$$\rho(r) = \int_{-\pi}^{+\pi} e^{ir\lambda} f(\lambda) d\lambda \quad (8.4.4)$$

此时 $\rho(r)$ 与 $f(\lambda)$ 可看作是互为 F- 变换及其逆变换.

定理 8.4.4 设 $\rho(\tau)$ 是均方连续的平稳过程 $X_T = \{X(t), t \in (-\infty, +\infty)\}$ 的相关函数, 则 $\rho(\tau)$ 可表示为:

$$\rho(\tau) = \int_{-\infty}^{+\infty} e^{i\tau\lambda} dF(\lambda) \quad (8.4.5)$$

其中 $F(\lambda)$ 是 $\lambda \in R$ 上的分布函数, 称 $F(\lambda)$ 为 $\rho(\tau)$ 的功率谱函数.

若 X_T 为实 r.v., 则:

$$\rho(\tau) = 2 \int_0^{\infty} \cos \tau\lambda dF(\lambda) \quad (8.4.6)$$

8.4 平稳过程的谱分解和协方差函数 (相关函数) 的谱分解

若 $\rho(\tau)$ 满足: $\int_{-\infty}^{+\infty} |\rho(\tau)| d\tau < \infty$, 则 $F'(\lambda) = f(\lambda)$ 存在, 称 $f(\lambda)$ 是功率谱密度函数, 且:

$$f(\lambda) = \frac{1}{2\pi} \int_{-\infty}^{+\infty} e^{-i\lambda\tau} \rho(\tau) d\tau \quad (8.4.7)$$

$$\rho(\tau) = \int_{-\pi}^{+\pi} e^{i\tau\lambda} f(\lambda) d\lambda \quad (8.4.8)$$

(8.4.7), (8.4.8) 可看作是连续参数情形下的 F-变换及其逆变换.

定理 8.4.3, 8.4.4 所阐述的平稳序列 (过程) 的基本特性, 最初是由 N.Wiener 及 A.Khintchine 得到的, 因此通常称为 Wiener-Khintchine 定理.

例 1 设 $\{\xi_n, n \in Z\}$ 为白噪声 (见 § 8.1 例), 则

$$\rho(r) = \begin{cases} 1 & r = 0 \\ 0 & r \neq 0 \end{cases} \quad \sum_{r \in Z} |\rho(r)| < +\infty.$$

故 $f(\lambda) = F'(\lambda)$ 存在, 且易得:

$$f(\lambda) = \frac{1}{2\pi} \sum_{r=-\infty}^{+\infty} e^{-i\lambda r} \rho(r) = \frac{1}{2\pi}.$$

亦即白噪声的谱密度为常数. 这个性质与光学中的白光的性质相同, 这就是“白噪声”名称的由来. 这个性质说明了白噪声是角频率在 $[-\pi, \pi]$ 上均匀分布的不相关的随机简谐运动叠加而成的, 即其不同频率的平均功率是均匀的.

例 2 AR(1) 模型

由上一节知道 $\rho(r) = a^{|r|}$, $|a| < 1$, 则有:

$$\sum_{r=-\infty}^{+\infty} |\rho(r)| = \sum_{r=-\infty}^{-1} |a|^{-r} + 1 + \sum_{r=1}^{+\infty} |a|^r < +\infty$$

故 $f(\lambda)$ 存在, 且:

$$f(\lambda) = \frac{1}{2\pi} + \frac{1}{2\pi} \left(\sum_{r=-\infty}^{-1} e^{-i\lambda r} a^{-r} + \sum_{r=1}^{+\infty} e^{-i\lambda r} a^r \right) = \frac{1}{2\pi} \cdot \frac{1 - a^2}{1 - 2a \cos \lambda + a^2}.$$

例 3 随机信号 (图象, 数据等) 的传送

在信号传输中, 信号是由不同的电流符号表示的, 电流的发送时间又有随机的持续时间. 设 $X(t)$ 代表 t 时刻的电流, 且 $\{X(t), t \in R\}$ 是平稳过程, $P(X(t) = 1) = P(X(t) = -1) = \frac{1}{2}$, $X(t)$ 在任一区间 $(t, t+h]$ 内发生跳变的次数是一个简单 Poisson 流, 即令:

$$\tau_1 = \inf\{t : t > -\infty, X(t) \neq X(-\infty)\}$$

$$\tau_n = \inf\{t : t > \tau_{n-1}, X(t) \neq X(\tau_{n-1})\} \quad n \geq 1, \forall t > 0$$

$$N(t) = \sup\{n : \tau_n \leq t\}$$

则有: $\forall t > 0, h \geq 0$

$$P(N(t+h) - N(t) = k) = \frac{(uh)^k}{k!} e^{-uh} \quad k = 0, 1, 2, \dots,$$

对 $\forall t \in (-\infty, +\infty)$, 易知 $EX(t) = 0$, 故 $R(t+\tau, t) = E(X(t+\tau)X(t)) \quad \tau \geq 0$ 而:

$$(X(t+\tau)X(t) = 1) = \bigcup_{k=0}^{+\infty} (N(t+\tau) - N(t) = 2k)$$

$$(X(t+\tau)X(t) = -1) = \bigcup_{k=0}^{+\infty} (N(t+\tau) - N(t) = 2k+1)$$

故:

$$R(t+\tau, t) = 1 \times \sum_{k=0}^{\infty} \frac{(u\tau)^{2k}}{(2k)!} e^{-u\tau} + (-1) \times \sum_{k=0}^{\infty} \frac{(u\tau)^{2k+1}}{(2k+1)!} e^{-u\tau} = e^{-2u\tau}$$

又因为 X_T 为实 r.v., 故 $\rho(-\tau) = \rho(\tau)$, 有: $\rho(\tau) = e^{-2u|\tau|} \quad \tau \in R$, 所以 X_T 是宽平稳过程, 且 $\int_{-\infty}^{+\infty} |\rho(\tau)| d\tau = \frac{1}{u} < \infty$, 由此可得

$$f(\lambda) = \frac{1}{2\pi} \int_{-\infty}^{+\infty} e^{-i\lambda\tau} \rho(\tau) d\tau = \frac{2u}{\pi(\lambda^2 + 4u^2)}.$$

例 4 连续参数 AR(1) 模型, 见 (8.3.18)

由上一节已得 $X(t) = \int_{-\infty}^t e^{-a(t-u)} dB(u)$, 故 $EX(t) = 0$, 且 $\forall \tau \geq 0$ 有:

$$\begin{aligned} E(X(t+\tau)X(t)) &= E \int_{-\infty}^{t+\tau} e^{-a(t+\tau-u)} dB(u) \int_{-\infty}^t e^{-a(t-v)} dB(v) \\ &= \int_{-\infty}^t \int_{-\infty}^{t+\tau} e^{-a(t+\tau-u)} e^{-a(t-v)} E(dB(u)dB(v)) \\ &= e^{-a\tau} \int_{-\infty}^t e^{-2a(t-v)} dv = \frac{e^{-a\tau}}{2a} \quad (\tau \geq 0) \end{aligned}$$

故对 $\forall \tau \in R$, 有 $R(\tau) = \frac{1}{2a} e^{-a|\tau|}$, 由此得:

$$\rho(\tau) = e^{-a|\tau|}.$$

同例 3, 可知 $f(\lambda) = \frac{a}{\pi(\lambda^2 + a^2)}$.

例 5 设

$$f(\lambda) = \frac{\lambda^2 + 4}{2\lambda(\lambda^4 + 10\lambda^2 + 9)}$$

求 $\rho(\tau)$.

解:

283

$$\rho(\tau) = \int_{-\infty}^{+\infty} e^{i\tau\lambda} f(\lambda) d\lambda = \frac{1}{48} (9e^{|\tau|} + 5e^{-3|\tau|})$$

8.4 平稳过程的谱分解和协方差函数 (相关函数) 的谱分解

3. 平稳过程的谱分解

谱分解是平稳过程 (序列) 的共同特性. 对于离散参数的平稳序列, 我们有以下的定理具体阐述这一特性.

定理 8.4.5 设 $X_n = \{X_n, n \in Z\}$ 为宽平稳序列, $EX_n = 0, R(r) = E(X_{n+r}\overline{X_n}), \rho(r) = R(r)/R(0), r \in Z$. 则一定存在一个正交增量过程 $\{\xi(\lambda), \lambda \in [-\pi, \pi]\}$, 满足:

$$X_n = \int_{-\pi}^{\pi} e^{in\lambda} d\xi(\lambda) \quad (8.4.9)$$

且:

$$R(r) = R(0) \int_{-\pi}^{\pi} e^{ir\lambda} dF(\lambda) \quad (8.4.10)$$

其中,

- 1) $\xi(\lambda) = \frac{1}{2\pi} \{ \lambda X_0 - \sum_{n \neq 0} \frac{e^{-in\lambda}}{in} X_n \} \quad \lambda \in [-\pi, \pi], \quad E\xi(\lambda) = 0.$
- 2) $F(\lambda) = E|\xi(\lambda)|^2 / E|\xi(\pi)|^2, \lambda \in [-\pi, \pi]$ 为 X_n 的相关函数 $\rho(r)$ 的功率谱分布

$$F(\lambda_2) - F(\lambda_1) = E|\xi(\lambda_2) - \xi(\lambda_1)|^2 / E|\xi(\pi)|^2 \quad \forall -\pi \leq \lambda_1 \leq \lambda_2 \leq \pi$$

即任一宽平稳序列可分解为角频率在 $[-\pi, \pi]$ 上, 且角频率互不相同, 对应的随机振幅互不相关的一系列随机简谐运动的叠加.

对于连续参数的平稳过程, 则有:

定理 8.4.6 设 $X_T = \{X(t), t \in (-\infty, +\infty)\}$ 为宽平稳过程且均方连续, $EX(t) = 0, R(\tau) = E(X(t+\tau)\overline{X(t)}), \rho(\tau) = R(\tau)/R(0)$, 则必存在一个正交增量过程 $\{\xi(\lambda), \lambda \in (-\infty, \infty)\}$, 满足:

$$X(t) = \int_{-\infty}^{+\infty} e^{it\lambda} d\xi(\lambda) \quad (8.4.11)$$

且:

$$R(\tau) = R(0) \int_{-\infty}^{+\infty} e^{i\tau\lambda} dF(\lambda) \quad (8.4.12)$$

其中,

- 1) $\xi(\lambda) \stackrel{m.s.}{=} \lim_{T \rightarrow \infty} \frac{1}{2\pi} \int_{-T}^T \frac{e^{i\lambda t} - 1}{-it} X(t) dt \quad \lambda \in (-\infty, +\infty)$
- 2) $F(\lambda) = E|\xi(\lambda)|^2 / E|\xi(+\infty)|^2.$

$$F(\lambda_2) - F(\lambda_1) = E|\xi(\lambda_2) - \xi(\lambda_1)|^2 / E|\xi(+\infty)|^2 \quad \forall \lambda_1 \leq \lambda_2$$

$F(\lambda)$ 称作 X_T 的相关函数 $\rho(r)$ 的功率谱分布. 这说明, 对平稳过程 (序列) 均可看作是随机简谐运动 (不同角频率对应的随机振幅不相关) 的叠加.

上述定理的证明见参考书 [6,15], 这里从略.

定理 8.4.5, 8.4.6 不仅指出了宽平稳过程的谱分解的必然存在性, 同时指出了这种分解是唯一依赖于平稳过程本身的.

§ 8.5 最佳均方预测与最佳线性均方预测

1. 最佳均方预测

预测所要解决的问题是, 已知一个时间序列现在与过去的数值 X_1, X_2, \dots, X_n , 对将来的数据 $X_{n+k}, (k \geq 1)$ 进行估计和预测. 下面我们给出最佳均方预测的一般数学表述.

设有一可观测的随机序列 $X_T = \{X_n, n \in N\}$ (有限或无限均可), 及一个随机变量 Y , 若用 X_1, X_2, \dots, X_n 的某个函数 $f(X_1, X_2, \dots, X_n)$ 作为 Y 的预测 (估计). 记作 $\hat{Y} = f(X_1, X_2, \dots, X_n)$, 其误差为 $(Y - \hat{Y})$. 我们能得到在由 X_1, X_2, \dots, X_n 给出 Y 的估计 (或预测) 中的最佳均方预测 \hat{Y}^* 满足:

$$E|Y - \hat{Y}^*|^2 = \inf_f E|Y - f(X_1, X_2, \dots, X_n)|^2$$

即在所有 X_1, X_2, \dots, X_n 的函数中, 寻找一个使均方预测误差达到最小的预测 (或估计) \hat{Y}^* .

根据定义, 我们有以下的定理.

定理 8.5.1 若 $E(Y|X_1, X_2, \dots, X_n)$ 存在, 则取 $\hat{Y}^* = E(Y|X_1, X_2, \dots, X_n)$,

$$E|Y - E(Y|X_1, X_2, \dots, X_n)|^2 \equiv \inf_f E|Y - f(X_1, X_2, \dots, X_n)|^2$$

证: $\forall f(X_1, \dots, X_n)$, 有

$$\begin{aligned} E|Y - f(X_1, \dots, X_n)|^2 &= E|(Y - E(Y|X_1, \dots, X_n)) + E(Y|X_1, \dots, X_n) - f(X_1, \dots, X_n)|^2 \\ &= E|Y - E(Y|X_1, X_2, \dots, X_n)|^2 + E|E(Y|X_1, \dots, X_n) - f(X_1, \dots, X_n)|^2 \\ &\quad + 2E[E(Y|X_1, \dots, X_n) - f(X_1, \dots, X_n)][Y - E(Y|X_1, X_2, \dots, X_n)] \\ &\geq E|Y - E(Y|X_1, X_2, \dots, X_n)|^2 + \\ &\quad 2E\{[E(Y|X_1, \dots, X_n) - f(X_1, \dots, X_n)][Y - E(Y|X_1, X_2, \dots, X_n)]\} \end{aligned}$$

下面证明上式第二项为 0. 由条件数学期望的性质, 有:

$$\begin{aligned} E\{[E(Y|X_1, \dots, X_n) - f(X_1, \dots, X_n)][Y - E(Y|X_1, X_2, \dots, X_n)]\} \\ &= E\{E[(E(Y|X_1, \dots, X_n) - f(X_1, \dots, X_n))(Y - E(Y|X_1, X_2, \dots, X_n))|X_1, \dots, X_n]\} \\ &= E[(E(Y|X_1, \dots, X_n) - f(X_1, \dots, X_n))(E(Y|X_1, X_2, \dots, X_n) - E(Y|X_1, X_2, \dots, X_n))] \\ &= 0 \end{aligned}$$

故: $E|Y - f(X_1, X_2, \dots, X_n)|^2 \geq E|Y - E(Y|X_1, X_2, \dots, X_n)|^2, \quad \forall f$

例 1 若 $(X, Y) \sim N(\mu_1, \mu_2, \sigma_1^2, \sigma_2^2, \rho)$, 若已知 X , 预测 Y , 则由正态过程的性质及以上定理有:

$$\hat{Y}^* = E(Y|X) = \mu_2 + \rho \frac{\sigma_2}{\sigma_1}(X - \mu_1)$$

8.5 最佳均方预测与最佳线性均方预测

例2 AR(1) 模型

设 $\xi_n \sim N(0, \sigma^2)$ 为正态白噪声, $\{X_n, n \in \mathbb{Z}\}$ 满足 $X_n - aX_{n-1} = \xi_n$,

1) 用 X_n, X_{n-1}, \dots 预测 X_{n+1} , 求 \hat{X}_{n+1}^* .

因 ξ_n 为正态白噪声, 故 $\{\xi_n, n \in \mathbb{Z}\}$ 相互独立, 且 ξ_{n+1} 与 X_n, X_{n-1}, \dots 独立, 再由 $X_{n+1} - aX_n = \xi_{n+1}$ 得: $E(X_{n+1}|X_n, X_{n-1}, \dots) - aE(X_n|X_n, X_{n-1}, \dots) = E(\xi_{n+1}|X_n, X_{n-1}, \dots) = 0$, 即 $\hat{X}_{n+1}^* = E(X_{n+1}|X_n, X_{n-1}, \dots) = aX_n$. 而其最佳均方误差为: $E|X_{n+1} - \hat{X}_{n+1}^*|^2 = E(X_{n+1} - aX_n)^2 = E\xi_{n+1}^2 = \sigma^2$.

2) 用 X_n, X_{n-1}, \dots 预测 X_{n+m} (m 步预测, $m \geq 1$), 求最佳均方预测 \hat{X}_{n+m}^* .

在方程 $X_{n+m} - aX_{n+m-1} = \xi_{n+m}$ 两边对 (X_n, X_{n-1}, \dots) 取条件数学期望, 并注意到 ξ_{n+1} 与 X_n, X_{n-1}, \dots 独立, 有 $E(X_{n+m}|X_n, X_{n-1}, \dots) - aE(X_{n+m-1}|X_n, X_{n-1}, \dots) = 0$, 即: $E(X_{n+m}|X_n, X_{n-1}, \dots) = aE(X_{n+m-1}|X_n, X_{n-1}, \dots)$, 依次递推可得:

$$E(X_{n+m}|X_n, X_{n-1}, \dots) = a^m X_n = \hat{X}_{n+m}^*$$

其均方误差为:

$$\begin{aligned} \mu_{n+m} &= E|X_{n+m} - a^m X_n|^2 = E|\xi_{n+m} + a\xi_{n+m-1} + \dots + a^{m-1}\xi_{n+1}|^2 \\ &= \sigma^2(1 + a^2 + \dots + a^{2m-2}) = \sigma^2 \frac{1 - a^{2m}}{1 - a^2} \quad |a| < 1 \end{aligned}$$

显然, m 步预测误差随 m 的增大会增大. 而且我们可以看到, 对 AR(1) 模型, 用 X_n, X_{n-1}, \dots 预测 \hat{X}_{n+m}^* 与用 X_n 预测 \hat{X}_{n+m}^* 的效果是一样的.

2. 线性均方最佳预测

用 Y 关于 X_n, X_{n-1}, \dots 的条件数学期望 $E(Y|X_n, X_{n-1}, \dots)$ 作为 Y 的最佳均方预测. 在理论上是一个很漂亮的结果 (见定理 8.5.1). 但是在很多实际情况下, 准确求出其条件数学期望往往是相当困难的, 甚至有时根本无法求出. 于是, 我们只能退而求其次. 一个很自然的想法便是放弃在一切函数范围内寻找最优的目标, 而只限制在线性函数的范围内求最佳均方预测 (估计). 这就是下面要讨论的线性均方预测问题. 其确切叙述如下:

设 $\{Y, X_n, X_{n-1}, \dots\} \in H$ 空间, $H_n = \{X_n, X_{n-1}, \dots\}$ 的线性组合及其均方极限全体, 称 H_n 为由 X_n, X_{n-1}, \dots 张成的线性空间.

若对于 $\hat{Y}^* = \sum_{k=0}^{\infty} \alpha_k X_{n-k} \in H_n$, 满足 $\forall \hat{Y} \in H_n$ 有

$$E|Y - \hat{Y}^*|^2 \leq E|Y - \hat{Y}|^2 \quad \text{或} \quad 286 E|Y - \hat{Y}^*|^2 = \inf_{\hat{Y} \in H_n} E|Y - \hat{Y}|^2 \quad (8.5.1)$$


则称 \hat{Y}^* 是 Y 的线性均方最佳预测.

可见, 线性均方最佳预测是以牺牲一定程度的预测精度, 来换得预测的可操作性. 下面我们可以深入考察这种预测的结果.

等式 8.5.1 表明 \hat{Y}^* 满足:

$$d(Y, \hat{Y}^*) = \inf_{\hat{Y} \in H_n} d(Y, \hat{Y}) \quad (8.5.2)$$

即要求 $\|Y - \hat{Y}^*\| = d(Y, \hat{Y}^*)$ 是 Y 到超平面 H_n 的最短距离. 故其几何表示如下图所示



显然, \hat{Y}^* 满足 (8.5.1) 的充要条件是: \hat{Y}^* 满足

$$(Y - \hat{Y}^*) \perp H_n \quad (8.5.3)$$

即 \hat{Y}^* 是 Y 在 H_n 上的投影. 又因 $\forall u, v \in H$, $u \perp v \iff (u, v) = 0$, 故, $(Y - \hat{Y}^*) \perp H_n$ 的充要条件是: $\forall u \in H_n$, 满足:

$$(Y - \hat{Y}^*, u) = E[(Y - \hat{Y}^*)\bar{u}] = 0 \quad (8.5.4)$$

即满足 (8.5.4) 的 \hat{Y}^* 是 Y 在 H_n 上的线性均方最佳预测.

定理 8.5.2 设 $\{Y, X_n, X_{n-1}, \dots, \} \in H$ 空间, H_n 为由 X_n, X_{n-1}, \dots 张成的线性空间. 则 \hat{Y}^* 是 Y 在 H_n 上的线性均方最佳预测的充要条件是, $\forall u \in H_n$, 满足:

$$E[(Y - \hat{Y}^*)\bar{u}] = 0$$

记作 $\hat{Y}^* = P_{H_n} Y$.

(1) 宽平稳过程的线性均方预测

设 $\{X_n, n \in Z\}$ 是实宽平稳过程, 其协方差函数, 相关函数分别为: $\{R(r), r \in Z\}, \{\rho(r), r \in Z\}$. 已知 $X_n, X_{n-1}, \dots, X_{n-p}$, 试求 X_{n+1} 的线性均方最佳预测 \hat{X}_{n+1}^* .

可令 $\hat{X}_{n+1}^* = \sum_{k=0}^p \alpha_k X_{n-k}$. 由 (8.5.4) 得 $\forall X_l, l = n, n-1, \dots, n-p$ 有:

$$E[(X_{n+1} - \sum_{k=0}^p \alpha_k X_{n-k})X_l] = 0 \quad n-p \leq l \leq n \quad (8.5.5)$$

8.5 最佳均方预测与最佳线性均方预测

亦即：

$$\begin{cases} \alpha_0 R(0) + \alpha_1 R(1) + \alpha_2 R(2) + \cdots + \alpha_p R(p) = R(1) \\ \alpha_0 R(1) + \alpha_1 R(0) + \alpha_2 R(1) + \cdots + \alpha_p R(p-1) = R(2) \\ \vdots \\ \alpha_0 R(p) + \alpha_1 R(p-1) + \alpha_2 R(p-2) + \cdots + \alpha_p R(0) = R(p+1) \end{cases} \quad (8.5.6)$$

其向量形式为：

$$\begin{pmatrix} R(0) & R(1) & \cdots & R(p) \\ R(1) & R(0) & \cdots & R(p-1) \\ \vdots & \vdots & \ddots & \vdots \\ R(p) & R(p-1) & \cdots & R(0) \end{pmatrix} \begin{pmatrix} \alpha_0 \\ \alpha_1 \\ \vdots \\ \alpha_p \end{pmatrix} = \begin{pmatrix} R(1) \\ R(2) \\ \vdots \\ R(p+1) \end{pmatrix} \quad (8.5.7)$$

(8.5.7) 称为 Yule-Walker 等式，左边的矩阵称为 Toeplitz 矩阵。解 (8.5.6) 的方程组，求得： $\alpha = (\alpha_0, \alpha_1, \cdots, \alpha_p)$ ，代入 $\hat{X}_{n+1}^* = \sum_{k=0}^p \alpha_k X_{n-k}$ ，即得到 X_{n+1} 的线性均方最佳预测。

(2) AR(p) 模型的线性均方最佳预测

设 $X_T = \{X_n, n \in Z\}$ 满足：

$$\sum_{k=0}^p a_k X_{n-k} = \xi_n \quad (8.5.8)$$

其中， $a_0 = 1$ ， $\xi = \{\xi_n, n \in Z\}$ 为白噪声，且 $(a_k, k = 1, 2, \cdots, p)$ 满足 $\alpha(z) = \sum_{k=0}^p a_k z^k$ 的根在单位圆内。已知 X_n, X_{n-1}, \cdots ，求 X_{n+1} 的线性均方最佳预测 \hat{X}_{n+1}^* 。

记 $H_n(X), H_n(\xi)$ 分别为由 X_n, X_{n-1}, \cdots 和 ξ_n, ξ_{n-1}, \cdots 张成的线性空间。因 $X_n = \sum_{k=0}^{\infty} g_k \xi_{n-k} \in H_n(\xi)$ ，故 $H_n(X) \subset H_n(\xi)$ ，而由 (8.5.8) 知， $\xi_n \in H_n(X)$ ，即 $H_n(\xi) \subset H_n(X)$ 。故有： $H_n(X) = H_n(\xi)$ 。

且由白噪声的特点，有 $\forall k \geq 1, \xi_{n+k} \perp H_n(X)$ ，又因 $X_{n+1} = -\sum_{k=1}^p a_k X_{n+1-k} + \xi_{n+1}$ ，故：

$$\begin{aligned} \hat{X}_{n+1}^* &= P_{H_n} X_{n+1} = P_{H_n} \left(-\sum_{k=1}^p a_k X_{n+1-k} \right) + P_{H_n} (\xi_{n+1}) \\ &= -\sum_{k=1}^p a_k X_{n+1-k} + 0 = -(a_1 X_n + a_2 X_{n-1} + \cdots + a_p X_{n+1-p}) \end{aligned} \quad (8.5.9)$$

(3) 二阶矩过程中的线性均方最佳预测

设二阶矩过程 $X_T = \{X_n, n \in Z\}$ 满足： $EX_n = 0, R(n, m) = E(X_n \bar{X}_m)$ ，已知 $X_n, X_{n-1}, \cdots, X_{n-p}$ ，求 X_{n+1} 的线性均方最佳预测 \hat{X}_{n+1}^* 。

设 $\hat{X}_{n+1}^* = \sum_{k=0}^p \alpha_k X_{n-k}$, 则由前述分析易得:

$$E[(X_{n+1} - \sum_{k=0}^p \alpha_k X_{n-k})X_l] = 0 \quad n-p \leq l \leq n$$

展开即:

$$\begin{cases} \alpha_0 R(n, n) + \alpha_1 R(n-1, n) + \cdots + \alpha_p R(n-p, n) = R(n+1, n) \\ \alpha_0 R(n, n-1) + \alpha_1 R(n-1, n-1) + \cdots + \alpha_p R(n-p, n-1) = R(n+1, n-1) \\ \cdots \cdots \\ \alpha_0 R(n, n-p) + \alpha_1 R(n-1, n-p) + \cdots + \alpha_p R(n-p, n-p) = R(n+1, n-p) \end{cases}$$

解出 $\alpha = (\alpha_0, \alpha_1, \cdots, \alpha_p)$, 即可求得 \hat{X}_{n+1}^* .

§ 8.6 各态历经性 (或遍历性)

平稳过程的参数 $m(t), R(\tau), \rho(\tau)$ 等通常并不是已知的, 那么, 如何通过试验得到它们的估计 $\hat{m}(t), \hat{R}(\tau), \hat{\rho}(\tau)$ 呢? 最简单自然的方法莫过于通过多次重复试验得到多个样本函数, 从而用某一时刻的试验平均值来作为它们的估计. 然而, 对于平稳过程, 通常是采取另一方法作为估计.

首先, 我们来回忆强大数定律: 设 $\{X_n, n \geq 1\}$ i.i.d. 且 $EX_n = \mu < \infty$, 则:

$$P(\lim_{n \rightarrow \infty} \frac{1}{n} \sum_{i=1}^n X_i = \mu) = 1$$

即当 n 充分大时,

$$\tilde{X}_n = \frac{1}{n} \sum_{k=1}^n X_k \approx EX$$

这说明, 独立同分布序列按时间平均以概率 1 收敛到按统计平均. 那么, 平稳过程 (序列) 是否有类似的结果呢? 答案是肯定的.

设 $\{X(t), t \in R\}$ 是平稳过程, 则 $X(t)$ 事实上是 (ω, t) 的二元函数. 因此它可以有按空间 (样本) 的统计性质 (如 $m_X, R(\tau)$ 等), 也有在 $t \in R$ 上的时间平均. 后者的定义叙述如下:

若以下的均方极限存在, 则

$$\bar{X}(t) \triangleq \lim_{T \rightarrow \infty} \frac{1}{2T} \int_{-T}^T X(t) dt \quad (m.s. \text{意义下})$$

称为 $X(t)$ 在 $(-\infty, +\infty)$ 上的时间平均,

289

$$\bar{R}(t, t+\tau) \triangleq \lim_{T \rightarrow \infty} \frac{1}{2T} \int_{-T}^T (X(t)X(t+\tau) - \bar{X}(t)\bar{X}(t+\tau)) dt$$

8.6 各态历经性 (或遍历性)

称为 $X(t)$ 在 $(-\infty, +\infty)$ 上的时间协方差函数.

在工程技术上, 测量到很多个样本函数通常是很困难的, 甚至是不可能的. 而平稳过程的统计性质不随时间推移而改变, 因此, 我们希望得到:

$$\overline{X}(t) = m_X \quad a.s. \quad (8.6.1)$$

$$\overline{R}(t, t+\tau) = R(\tau) \quad a.s. \quad (8.6.2)$$

如果 (8.6.1) 式成立, 则称 $X(t)$ 具有数学期望的各态历经性, 即遍历性 (Ergodic).

如果 (8.6.2) 式成立, 则称 $X(t)$ 具有协方差函数的各态历经性.

应该指出, 并不是所有的平稳过程都具有各态历经性. 只有对过程本身加上一定的条件, 才能使它具有各态历经性. 这就是后面各态历经性定理要解决的问题. 在介绍它们之前, 先举一个具有各态历经性的平稳过程的例子.

例 1 设 $\{X(t) = a \cos(\omega_0 t + \Phi), t \in R\}$, 其中, a, ω_0 是正常数, 而 Φ 为区间 $[0, 2\pi]$ 上的均匀分布. 下面说明它是具有各态历经性的. 易知:

$$m_X(t) = E[a \cos(\omega_0 t + \Phi)] = a \int_0^{2\pi} \cos(\omega_0 t + \phi) \frac{1}{2\pi} d\phi = 0.$$

$$R(t, t+\tau) = E[X(t)X(t+\tau)] = \frac{1}{2}a^2 \cos \omega_0 \tau$$

即 $X(t)$ 是平稳过程, $m_X = 0, R(\tau) = \frac{1}{2}a^2 \cos \omega_0 \tau$. 而:

$$\overline{X}(t) = \lim_{T \rightarrow \infty} \frac{1}{2\pi} \int_{-T}^T a \cos(\omega_0 t + \Phi) dt = \lim_{T \rightarrow \infty} \frac{a}{2\pi} \int_{-T}^T [\cos \omega_0 t \cos \Phi - \sin \omega_0 t \sin \Phi] dt = 0 = m_X.$$

$$\overline{R}(t, t+\tau) = \lim_{T \rightarrow \infty} \frac{a^2}{2T} \int_{-T}^T \cos(\omega_0 t + \Phi) \cos[\omega_0(t+\tau) + \Phi] dt = \frac{1}{2}a^2 \cos \omega_0 \tau = R(\tau)$$

故 $X(t)$ 具有各态历经性.

下面我们就来讨论为了具有各态历经性, 一个平稳过程需要满足什么样的条件.

定理 8.6.1 连续参数平稳过程的数学期望的各态历经性定理

设 $\{X(t), -\infty < t < +\infty\}$ 是宽平稳过程, 则 $\overline{X}(t) = m_X$ a.s. 的充要条件是:

$$\lim_{T \rightarrow \infty} \frac{1}{T} \int_0^{2T} (1 - \frac{\tau}{2T}) R(\tau) d\tau = 0 \quad (8.6.3)$$

证: $\overline{X}(t)$ 本身是一个随机变量, 因此我们可以得到:

$$E\overline{X}(t) = E[\lim_{T \rightarrow \infty} \frac{1}{2T} \int_{-T}^T X(t) dt] = \lim_{T \rightarrow \infty} \frac{1}{2T} \int_{-T}^T EX(t) dt = m_X.$$

$$\begin{aligned} D\overline{X}(t) &= E(\overline{X}(t))^2 - (E\overline{X}(t))^2 = E[\lim_{T \rightarrow \infty} \frac{1}{2T} \int_{-T}^T X(t) dt]^2 - m_X^2 \\ &= \lim_{T \rightarrow \infty} \frac{1}{4T^2} \int_{-T}^T \int_{-T}^T R(t-s) ds dt \end{aligned}$$

由变量置换和 $R(\tau)$ 的偶函数性质, 可得, $\int_{-T}^T \int_{-T}^T R(t-s)dsdt = 2 \int_0^{2T} (2T-\tau)R(\tau)d\tau$, 故:

$$D\bar{X}(t) = \lim_{T \rightarrow \infty} \frac{1}{T} \int_0^{2T} (1 - \frac{\tau}{2T}) R(\tau) d\tau$$

因此, $\bar{X}(t) = m_X \iff \bar{X}(t) = E\bar{X}(t) \iff D\bar{X}(t) = 0 \iff (8.6.3)$ 式成立.

若只讨论时间为 $0 \leq \tau < \infty$ 的平稳过程, 上述充要条件改为:

$$\lim_{T \rightarrow \infty} \frac{1}{T} \int_0^T (1 - \frac{\tau}{T}) R(\tau) d\tau = 0 \quad (8.6.4)$$

即可.

推论 若平稳过程 X_T 满足 $\lim_{\tau \rightarrow \infty} R(\tau) = 0$, 则 X_T 具有数学期望的各态历经性.

证: 根据极限的定义知: $\forall \varepsilon > 0, \exists T_\varepsilon > 0$, 当 $\tau \geq T_\varepsilon$ 时 $|R(\tau)| < \varepsilon$, 故

$$\begin{aligned} |\frac{1}{T} \int_0^{2T} (1 - \frac{\tau}{2T}) R(\tau) d\tau| &\leq \frac{1}{T} \int_0^{2T} |R(\tau)| d\tau \\ &\leq \frac{1}{T} \int_0^{T_\varepsilon} |R(\tau)| d\tau + \frac{1}{T} \int_{T_\varepsilon}^{2T} |R(\tau)| d\tau \\ &\leq \frac{1}{T} \int_0^{T_\varepsilon} |R(\tau)| d\tau + \frac{1}{T} (2T - T_\varepsilon) \varepsilon \xrightarrow{T \rightarrow \infty} 0 \end{aligned}$$

故由定理 (8.6.1) 可以得到结论.

这个推论给出了平稳过程具有数学期望各态历经性的一个充分条件. 它说明, 当时间间隔无限大时的两状态不相关时, 平稳过程具有数学期望各态历经性.

定理 8.6.2 离散参数平稳过程数学期望的各态历经性定理

设 $\{X_n, n = 0, 1, 2, \dots\}$ 是平稳序列, 则:

$$\lim_{n \rightarrow \infty} \frac{1}{n} \sum_{k=0}^{n-1} X_k = m_X \quad a.s.$$

成立的充要条件是:

$$\lim_{n \rightarrow \infty} \frac{1}{n} \sum_{k=0}^{n-1} (1 - \frac{k}{n}) R(k) = 0 \quad (8.6.5)$$

证明类似于定理 (8.6.1), 从略.

定理 8.6.3 连续参数平稳过程的协方差函数各态历经性定理

设 $\{X(t), t \in R\}$ 是平稳过程, 且对任意给定的 $\tau, \{X(t)X(t+\tau), t \in R\}$ 是平稳过程, 则 $\bar{R}(t, t+\tau) = R(\tau)$, $a.s.$ 成立的充要条件是:

$$\lim_{T \rightarrow \infty} \frac{1}{T} \int_0^{2T} (1 - \frac{\tau_1}{2T}) [\bar{R}_\tau(\tau_1) R'(\tau)] d\tau_1 = 0 \quad (8.6.6)$$

其中, $\bar{R}_\tau(\tau_1) = E[X(t)X(t+\tau)X(t+\tau_1)X(t+\tau+\tau_1)], R'(\tau) = E[X(t)X(t+\tau)]$.

8.7 线性系统中的平稳过程

证: 当 τ 固定时, $R'(\tau) = E[X(t)X(t+\tau)]$ 是随机过程 $\{Y_\tau(t) \triangleq X(t)X(t+\tau), t \in R\}$ 的数学期望. 故, $X(t)$ 的协方差函数各态历经性等价于 $Y_\tau(t)$ 的数学期望的各态历经性. ($\forall \tau \in R$)

由题设条件, 知 $\forall \tau \in R, \{Y_\tau(t), t \in R\}$ 是平稳过程. 又:

$$\begin{aligned} \text{Cov}(Y_\tau(t), Y_\tau(t+\tau_1)) &= \text{Cov}(X(t)X(t+\tau), X(t+\tau_1)X(t+\tau+\tau_1)) \\ &= E[X(t)X(t+\tau)X(t+\tau_1)X(t+\tau+\tau_1)] \\ &\quad - E[X(t)X(t+\tau)]E[X(t+\tau_1)X(t+\tau+\tau_1)] \\ &= \bar{R}_\tau(\tau_1) - (R'(\tau))^2 \end{aligned}$$

于是, 由定理 8.6.1, 可得结论.

若只讨论时间为 $0 \leq t < \infty$ 的平稳过程, 定理 8.6.3 的充要条件改为:

$$\lim_{T \rightarrow \infty} \frac{1}{T} \int_0^T (1 - \frac{\tau_1}{T}) [\bar{R}_\tau(\tau_1) - (R'(\tau))^2] d\tau_1 = 0 \quad (8.6.7)$$

即可.

定理 8.6.3 离散参数平稳序列的协方差函数各态历经性定理

设 $\{X_n, n = 0, 1, 2, \dots\}$ 是平稳序列, 且对任意固定的非负整数 $m, \{X_n X_{n+m}, n = 0, 1, 2, \dots\}$ 是平稳序列. 则:

$$\lim_{n \rightarrow \infty} \frac{1}{n} \sum_{k=0}^{n-1} X_k X_{k+m} = R(m) \quad a.s.$$

成立的充要条件是:

$$\lim_{n \rightarrow \infty} \frac{1}{n} \sum_{k=0}^{n-1} (1 - \frac{k}{n}) [\bar{R}_m(k) - (R'(m))^2] = 0 \quad (8.6.8)$$

其中, $\bar{R}_m(k) = E(X_n X_{n+m} X_{n+k} X_{n+m+k}), R'(m) = E X_n X_{n+m}$.


一般地, 宽平稳过程不能保证 $\{X(t)X(t+\tau), t \in R\}, \forall \tau \in R$ (或 $\{X_n X_{n+m}, n = 0, 1, 2, \dots\}, \forall m \in N \cup \{0\}$) 也是平稳的, 因此, 它们要成为协方差函数各态历经性的前提假设.

§ 8.7 线性系统中的平稳过程

线性系统是工程与物理中最常见的一类系统, 它是满足叠加原理的一类系统, 在这种系统中, 如果输入是一个平稳过程, 其输出也应是平稳过程. 但输出的随机过程是否也平稳呢? 输入, 输出之间的线性关系 (相关性) 又是怎样的呢? 本节将要讨论这些问题.

(1) 线性系统

一个系统可以用以下图示代表：



其中, $x(t), y(t)$ 分别代表输入, 输出量, L 是系统的运算子, 它表示输入, 输出之间的运算关系满足: $y(t) = L[x(t)]$.

定义 设有系统 L , 且 $y_1(t) = L[x_1(t)], y_2(t) = L[x_2(t)]$, 如果它对于任意常数 c_1, c_2 满足:

$$c_1 y_1(t) + c_2 y_2(t) = L[c_1 x_1(t) + c_2 x_2(t)] \quad (8.7.1)$$

则称 L 是线性系统.

定义 若系统 L 对任意 τ 有:

$$L[x(t + \tau)] = y(t + \tau) \quad (8.7.2)$$

则称 L 是定常系统 (或时不变系统).

工程中, 定常线性系统可用微分方程描述, 如:

$$b_n \frac{d^n y}{dt^n} + b_{n-1} \frac{d^{n-1} y}{dt^{n-1}} + \cdots + b_0 y = a_m \frac{d^m x}{dt^m} + a_{m-1} \frac{d^{m-1} x}{dt^{m-1}} + \cdots + a_0 x \quad (8.7.3)$$

其中, $n > m \geq 0, t \in R$.

对 $x(t), y(t)$ 分别进行拉普拉斯变换, 即:

$$X(s) = \mathcal{L}[x(t)] = \int_{-\infty}^{\infty} x(t)e^{-st} dt$$

$$Y(s) = \mathcal{L}[y(t)] = \int_{-\infty}^{\infty} y(t)e^{-st} dt$$

则 8.7.3 式变为:

$$Y(s) = H(s)X(s) \quad (8.7.4)$$

其中,

$$H(s) = \frac{a_m s^m + a_{m-1} s^{m-1} + \cdots + a_0}{b_n s^n + b_{n-1} s^{n-1} + \cdots + b_0} \quad (8.7.4a)$$

它完全由系统的状态特性所确定, 称为系统的传递函数. 记 $h(t) = \mathcal{L}^{-1}[H(s)]$, 则 $h(t)$ 描绘了系统的动态特性, 称为线性系统的脉冲响应函数. 由 8.7.4 作拉氏反变换得到

$$y(t) = \int_{-\infty}^{\infty} x(t - \lambda)h(\lambda)d\lambda \quad (8.7.5)$$

取 $s = i\omega$, 则, $H(i\omega) = \int_{-\infty}^{\infty} h(t)e^{-i\omega t} dt$ 是 $h(t)$ 的傅里叶变换, 称为系统的频率响应函数.

8.7 线性系统中的平稳过程

关于定常线性系统的内容, 很多工程类书籍中都有介绍, 这里只列出几个基本概念, 读者可以自行查阅工程类参考书.

(2) 线性系统输出过程的概率特性

以下讨论的线性系统的输入都是平稳过程 $\{X(t), t \in R\}$, 由 (8.7.5) 设线性系统的输出过程为:

$$y(t) = \int_0^\infty x(t-\lambda)h(\lambda)d\lambda \quad (8.7.6)$$

定理 8.7.1 设定常线性系统 L 的脉冲响应函数为 $h(t), (t \geq 0)$. 若输入 $\{X(t), t \in R\}$ 是平稳过程, 且 $EX(t) = m_X$, 协方差函数为 $R_X(\tau)$. 则系统输出 $Y(t)$ 也是一个平稳过程, 且

$$EY(t) = m_X \int_0^\infty h(\lambda)d\lambda$$

当 $m_X = 0$ 时,

$$Cov(Y(t), Y(t+\tau)) = R_Y(\tau) = \int_0^\infty \int_0^\infty R_X(\lambda_2 - \lambda_1 - \tau)h(\lambda_1)h(\lambda_2)d\lambda_1d\lambda_2.$$

证:

$$\begin{aligned} EY(t) &= E\left[\int_0^\infty X(t-\lambda)h(\lambda)d\lambda\right] \\ &= \int_0^\infty E[X(t-\lambda)]h(\lambda)d\lambda \quad \text{Fubini 定理} \\ &= \int_0^\infty m_X h(\lambda)d\lambda = EY(t) = m_X \int_0^\infty h(\lambda)d\lambda, \end{aligned}$$

当 $m_X = 0$ 时, $m_Y = 0$, 故,

$$\begin{aligned} R_Y(t, t+\tau) &= E[Y(t)Y(t+\tau)] \\ &= E\left[\int_0^\infty X(t-\lambda_1)h(\lambda_1)d\lambda_1 \int_0^\infty X(t+\tau-\lambda_2)h(\lambda_2)d\lambda_2\right] \\ &= \int_0^\infty \int_0^\infty E[X(t-\lambda_1)X(t+\tau-\lambda_2)]h(\lambda_1)h(\lambda_2)d\lambda_1d\lambda_2 \\ &= \int_0^\infty \int_0^\infty R_X(\lambda_2 - \lambda_1 - \tau)h(\lambda_1)h(\lambda_2)d\lambda_1d\lambda_2 \end{aligned}$$

显然, $Y(t)$ 的均值函数与协方差函数都与时间 t 无关, 所以它是宽平稳过程.

在 (8.4) 中我们已经介绍了平稳过程的协方差函数的 (功率) 谱分解, 并得到协方差函数与谱密度之间的傅立叶变换关系. 在线性系统中, 我们把一个平稳过程的协方差函数的傅氏变换称为它的谱密度函数, 而把两个平稳过程的互协方差函数的傅氏变换称为它的互谱密度函数. 类似于平稳过程的概念, 当互协方差函数不随时间改变时, 称它们平稳相关.

定理 8.7.2 系统 L 加上定理 8.7.1, 若 $\{X(t), t \in R\}$ 的谱密度函数为 $f_X(\omega)$, 当 $m_X = m_Y = 0$ 时, $Y(t)$ 的谱密度函数为:

$$f_Y(\omega) = |H(i\omega)|^2 f_X(\omega)$$

其中, $H(i\omega)$ 由 (8.7.4) 式定义.

证: 由定理 8.7.1

$$\begin{aligned} f_Y(\omega) &= \int_{-\infty}^{\infty} R_Y(\tau) e^{-i\omega\tau} d\tau \\ &= \int_{-\infty}^{\infty} \left[\int_0^{\infty} \int_0^{\infty} R_X(\lambda_2 - \lambda_1 - \tau) h(\lambda_1) h(\lambda_2) d\lambda_1 d\lambda_2 \right] e^{-i\omega\tau} d\tau \\ &= \int_0^{\infty} \int_0^{\infty} \left[\int_{-\infty}^{\infty} R_X(\lambda_2 - \lambda_1 - \tau) e^{-i\omega\tau} d\tau \right] h(\lambda_1) h(\lambda_2) d\lambda_1 d\lambda_2 \end{aligned}$$

由变量置换, 可知积分

$$\begin{aligned} \int_{-\infty}^{\infty} R_X(\lambda_2 - \lambda_1 - \tau) e^{-i\omega\tau} d\tau &= \int_{-\infty}^{\infty} R_X(-\tau_1) e^{-i\omega(\tau_1 + \lambda_2 - \lambda_1)} d\tau_1 \\ &= f_X(\omega) e^{-i\omega(\lambda_2 - \lambda_1)} \end{aligned}$$

故:

$$\begin{aligned} f_Y(\omega) &= f_X(\omega) \int_0^{\infty} h(\lambda_1) e^{i\omega\lambda_1} d\lambda_1 \int_0^{\infty} h(\lambda_2) e^{-i\omega\lambda_2} d\lambda_2 \\ &= f_X(\omega) H(-i\omega) H(i\omega) = |H(i\omega)|^2 f_X(\omega) \end{aligned}$$

定理 8.7.2 给出了输入, 输出过程的协方差函数的傅立叶变换之间的关系.

前面的讨论已经显示, 当定常线性系统的输入是平稳过程时, 其输出也是平稳过程. 那么这两个过程的线性相关性随时间推移有什么样的性质呢?

定理 8.7.3 系统 L 如定理 8.7.1 所示, 若输入 $\{X(t), t \in R\}$ 是平稳过程, 则它与输出过程是平稳相关的, 且当 $m_X = m_Y = 0$ 时, 互协方差函数和互谱密度函数分别为:

$$R_{XY}(\tau) = \int_0^{\infty} R_X(\tau - \lambda) h(\lambda) d\lambda$$

和

$$f_{XY}(\omega) = f_X(\omega) H(i\omega)$$

证:

$$\begin{aligned} R_{XY}(t, t + \tau) &= E[X(t)Y(t + \tau)] = E[X(t) \int_0^{\infty} X(t + \tau - \lambda) h(\lambda) d\lambda] \\ &= \int_0^{\infty} E[X(t)X(t + \tau - \lambda)] h(\lambda) d\lambda \\ &= \int_0^{\infty} R_X(\tau - \lambda) h(\lambda) d\lambda \end{aligned}$$

8.7 线性系统中的平稳过程

$$\begin{aligned} f_{XY}(\omega) &= \mathcal{F}[R_{XY}(\tau)] = \mathcal{F}\left[\int_0^\infty R_X(\tau - \lambda)h(\lambda)d\lambda\right] \\ &= \mathcal{F}[R_X(\tau)]\mathcal{F}[h(\lambda)] = f_X(\omega)\mathcal{F}[h(\lambda)] \\ &= f_X(\omega)H(i\omega) \end{aligned}$$

例 1 上一节中所介绍的 ARMA 模型就是一种定常线性系统.

例 2 设定常系统的输入, 输出微分方程为:

$$\frac{1}{a}y'(t) + y(t) = x(t)$$

则取 \mathcal{L} -变换有: $Y(s) = \frac{a}{s+a}X(s)$, 故 $H(s) = \frac{a}{s+a}$, 因此, 脉冲响应函数为:

$$h(t) = \mathcal{L}^{-1}[H(s)] = \begin{cases} ae^{-at}, & t \geq 0 \\ 0, & t < 0 \end{cases}$$

频率响应函数为: $H(i\omega) = \frac{a}{i\omega+a}$.

若输入平稳过程 $X(t)$ 满足, $m_X = 0, R_X(\tau) = \sigma^2 e^{-b|\tau|}, b > 0$ 且 $b \neq a$. 则由定理 8.7.1 易知, 输出过程的数学期望 $m_Y = EY(t) = 0$. 而输出过程的协方差函数有两种求法:

(1) 利用定理 8.7.1

$$R_Y(\tau) = \int_0^\infty \int_0^\infty \sigma^2 e^{-b|\lambda_2 - \lambda_1 - \tau|} a^2 e^{-a(\lambda_1 + \lambda_2)} d\lambda_1 d\lambda_2$$

解二重积分 (并利用 $R_Y(\tau)$ 的偶函数性质) 可得:

$$R_Y(\tau) = \frac{a\sigma^2}{a^2 - b^2} [ae^{-b|\tau|} - be^{-a|\tau|}], \quad -\infty < \tau < +\infty$$

(2) 利用定理 8.7.2 由 $f_X(\omega) = \mathcal{F}[R_X(\tau)] = 2b\sigma^2/(b^2 + \omega^2)$, $|H(i\omega)|^2 = a^2/(\omega^2 + a^2)$, 故:

$$f_Y(\omega) = \frac{a^2}{\omega^2 + a^2} \frac{2b\sigma^2}{b^2 + \omega^2}$$

由此可得:

$$R_Y(\tau) = \mathcal{F}^{-1}[f_Y(\omega)] = \frac{a\sigma^2}{a^2 - b^2} [ae^{-b|\tau|} - be^{-a|\tau|}], \quad -\infty < \tau < +\infty$$

可见, 两种方法殊途同归. 不过后者由于计算往往更为简便, 故在工程中更多的被采用.

练习题

8.1 设随机电报信号过程 $\{X(t), t \in R\}$ 只取 $+1$ 和 -1 两个状态, 且 $\forall t \in R, P(X(t) = 1) = P(X(t) = -1) = 1/2$. 记 $X(t)$ 在 $(s, s+t]$ 上符号改变的次数为 $N(s+t) - N(s) = \Delta N(s, s+t)$, 设它是参数为 μt 的 Poisson 分布. 试证: $\{X(t), t \in R\}$ 是宽平稳过程, 并求出其相关系数 $\rho(\tau)$ 及其功率谱密度.

8.2 设 $\{X(t), t \in R\}$ 为平稳过程, $EX(t) = 0$, $\rho_X(\tau)$ 为其相关函数, 令 $Y(t) = \begin{cases} 1 & X(t) \geq 0 \\ -1 & X(t) < 0 \end{cases}$ 试证 $\{Y(t), t \in R\}$ 为宽平稳过程. 求其相关函数 $\rho_Y(\tau)$.

8.3 设 $\{\xi(\lambda), \lambda \in R\}$ 是正交增量过程. $E\xi(\lambda) = 0$, $E|\xi(\lambda_2) - \xi(\lambda_1)|^2 = \lambda_2 - \lambda_1$. 试证 $X(t) = \xi(t) - \xi(t-1)$ 为平稳过程. 求其 $\rho_X, R(\tau)$ 与 $f_X(\tau)$.

8.4 设 $\{X(t), t \in R\}$ 为均方连续平稳过程, 其谱密度为 $f(\lambda)$. $\forall h > 0$, 记 $X_n^h \triangleq X(nh)$, 试证 $\{X_n^h, n \in Z\}$ 是平稳序列. 试用 $f(\lambda)$ 表示 $\{X_n^h, n \in Z\}$ 的谱密度.

8.5 试求平稳序列 $\{X_n, n \in Z\}$ 的相关系数 $\rho(\tau)$ 及谱密度 $f_X(\lambda)$, 若 X 满足:

1) $AR(1): X_n + aX_{n-1} = \xi_n \quad |a| < 1;$

2) $AR(2): X_n + a_1X_{n-1} + a_2X_{n-2} = \xi_n$; 其中, $\alpha(z) = 1 + a_1z + a_2z^2$ 的根在单位圆外.

3) $ARMA(1,1): X_n + aX_{n-1} = \xi_n + b_1\xi_{n-1} \quad |a| < 1, |b| < 1.$

8.6 设平稳过程 $\{X(t), t \in R\}$ 满足下列方程:

1) $dX(t) + aX(t) = dB(t) \quad a > 0;$

2) $X''(t) + a_1X'(t) + a_2X(t) = dB(t)/dt, \alpha(z) = z^2 + a_1z + a_2 = (z + \alpha_1)(z + \alpha_2) \quad \alpha_i > 0, \alpha_1 \neq \alpha_2.$

试求 $\rho_X(\tau)$ 及 $f_X(\lambda)$.

8.7 试求下列线性模型中 X_n 的显示表达式及格林传递函数.

1) $X_n - 0.6X_{n-1} = \xi_n;$

2) $X_n + 0.1X_{n-1} - 0.56X_{n-2} = \xi_n;$

3) $X_n - 1.4X_{n-1} + 0.49X_{n-2} = \xi_n;$

4) $X_n + 0.3X_{n-1} = \xi_n - 0.4\xi_{n-1};$

5) $X_n - 1.6X_{n-1} + 0.63X_{n-2} = \xi_n + 0.5\xi_{n-1};$

8.8 设 $AR(2)$ 模型为 $X_n - 2aX_{n-1} + a^2X_{n-2} = \xi_n$, 其中 $|a| < 1$.

1) 试证 X_n 的显示表达式 (传递形式) 为:

$$X_n = \sum_{k=0}^{\infty} (k+1) \frac{a^k}{297} \xi_{n-k}$$

2) 试求 $X_n - 1.2X_{n-1} + 0.36X_{n-2} = \xi_n$ 的 $\rho_X(r)$.

练习题

[提示: $r > 0$ 时, $\rho(r)$ 是差分方程 $\rho(r) - 1.2\rho(r-1) + 0.36\rho(r-2) = 0$ 的解, 其一般解为: $\rho(r) = C_1 0.6^r + C_2 r(0.6)^r$, 再利用 $\rho(0) = 1, \rho(1) = \rho(-1)$ 定出系数 C_1, C_2 .]

8.9 已知 AR(2) 模型 $X_n - 1.6X_{n-1} + 0.64X_{n-2} = \xi_n$, 其中, $\xi_n \sim N(0, \sigma^2)$ 是正态噪声. 已知观察值 X_1, \dots, X_k , 求 l 步最佳均方预测值 \hat{X}_{k+l} 和预测均方误差.

8.10 设 $\{X_n, n \geq 0\}$ 为宽平稳序列, $EX_n = 0$, 其协方差 $R(r)$ 已知

1) 若取 $\hat{X}_{n+1}(1) = aX_n$ 作为 X_{n+1} 的估计 (或预测), 试求其最佳线性均方估计, 并求相应的均方误差 $\Delta_n = E(X_{n+1} - \hat{X}_{n+1})^2$.

2) 若取 $\hat{X}_{n+1}(2) = bX_n + cX_{n-1}$ 作为 X_{n+1} 的估计, 试确定 b, c 使 $\hat{X}_{n+1}(2)$ 是 X_{n+1} 的最佳均方估计.

8.11 $\{X_n, n \geq 0\}$ 同题 8.10. 若 X_n, X_{n+N} 已知, 而 $X_{n+k}, (1 \leq k < N)$ 丢失, 试用 X_n, X_{n+N} 的线性函数 $\hat{X}_{n+k}^* = aX_n + bX_{n+N}$ 作为 X_{n+k} 的最佳均方估计 (内插), 试确定 a, b .

8.12 (线性滤波问题) $\{X_n, n \geq 0\}$ 为平稳序列, $EX_n = 0$, 其协方差 $R(r)$ 已知, 设 X_n 为系统在 n 时刻的状态 (不能观测), 其观测值包含白噪声, 即 $Z_n = X_n + \xi_n$, 其中 $\{\xi_n, n \geq 0\}$ 为白噪声序列, 且与 $\{X_n, n \geq 0\}$ 不相关, $E\xi_n = 0, E\xi_n^2 = \sigma^2$. 试用 $\hat{X}_n = aZ_n + bZ_{n-1}$ 作为 X_n 的估计. 试求其最佳均方估计 (滤波).

8.13 随机过程

$$X(t) = A \sin t + B \cos t, \quad -\infty < t < +\infty$$

其中, A, B 是均值为 0 且不相关的随机变量, 且 $EA^2 = EB^2$. 试讨论 $X(t)$ 的各态历经性.

8.14 设平稳过程 $\{X(t), -\infty < t < +\infty\}$, $EX(t) = 0, R(\tau) = Ae^{-a|\tau|}(1 + a|\tau|)$, 其中, A, a 是正常数. 试问 $X(t)$ 对数学期望是否有各态历经性.

8.15 设 $\{X(t), -\infty < t < +\infty\}$ 和 $\{Y(t), -\infty < t < +\infty\}$ 是平稳相关随机过程, 若 $X(t), Y(t)$ 满足:

$$Y'(t) + aY(t) = X(t)$$

其中, a 是非零常数. 试证: $m_Y = \frac{1}{a}m_X$.

8.16 均值为零的平稳过程 $\{X(t), -\infty < t < +\infty\}$, 输入到脉冲响应函数为

$$h(t) = \begin{cases} ae^{-at} & 0 \leq t \leq T \\ 0 & \text{其它} \end{cases} \quad (a > 0)$$

的线性滤波器, 试证它的输出功率谱密度为:

$$f_Y(\omega) = \frac{a^2}{a^2 + \omega^2} (1 - 2e^{-aT} \cos \omega T + e^{-2aT}) f_X(\omega)$$

其中, $f_X(\omega)$ 是 $X(t)$ 的谱密度函数.

8.17 设 $\{X_n, n \in Z\}$ 是满足方程 $AR(1): X_n - aX_{n-1} = \xi_n$ 的平稳解. (其中 $|a| < 1$, $\{\xi_n, n \in Z\}$ 为白噪声序列), 试用 X_n, X_{n-1} 的线性函数作为 X_{n+1} 的估计. 试求其最佳线性均方预测,

8.18 设 $\{X_n, n \in Z\}$ 为平稳序列, 相关函数为 $\rho(\tau)$ 及其功率谱函数为 $F(\lambda), \lambda \in [-\pi, \pi]$. 试用 X_{n-1}, \dots, X_{n-p} 的线性函数 $\hat{X}_n = \sum_{k=1}^p \alpha_k X_{n-k}$ 作为 X_n 的预测. 则它是最佳线性均方预测的充要条件是满足以下方程组:

$$\int_{-\infty}^{\infty} e^{ik\lambda} \left[1 - \sum_{l=1}^p \alpha_l e^{-il\lambda} \right] dF(\lambda) = 0, \quad k = 1, 2, \dots, p.$$

8.19 设 $\{\xi_n, n \geq 0\}$, i.i.d. $E\xi_n = 0, E\xi_n^2 = \sigma^2, \{X_n, n \geq 0\}$ 满足: $X_n = \sum_{k=0}^{\infty} \alpha_k \xi_{n-k}$, 其中, $\alpha_0 = 1, \sum_{k=1}^{\infty} \alpha_k^2 < +\infty$. 记 $U_n = \sum_{k=0}^n X_{k-1} \xi_k, V_n = \sum_{k=0}^n X_k \xi_k - (n+1)\sigma^2, n \geq 0$. 试证 $\{U_n, n \geq 0\}$ 及 $\{V_n, n \geq 0\}$ 关于 $\{\xi_n, n \geq 0\}$ 是鞅.

8.20 设 X_0 的 p.d.f. 是 $f(x) = 2xI_{(x \geq 0)}$, 对 $n \geq 1$ 给定 X_0, \dots, X_n, X_{n+1} 是 $(1 - X_n, 1]$ 上的均匀分布. 试证: $\{X_n, n \geq 0\}$ 是满足期望各态历经定理的平稳过程.

8.21 设 $X_0 = Z \sim U[0, 1], X_{n+1} = 2X_n \cdot I_{(X_n < 1/2)} + (2X_n - 1) \cdot I_{(X_n \geq 1/2)}$.

1) 试证: $\{X_n, n \geq 0\}$ 是平稳序列;

2) 若 Z 用二进制小数表示, 即 $Z = \sum_{k=0}^{\infty} 2^{-(k+1)} Z_k = 0.Z_0 Z_1 Z_2 \dots$, 其中 Z_k 取值 0 或 1, 试证 $X_n = 0.Z_n Z_{n+1} \dots$;

3) 利用 ergodic 定理, 证明:

$$\lim_{n \rightarrow \infty} \frac{1}{n} \sum_{k=1}^{n-1} \{2^k Z\} = \frac{1}{2} \quad a.s.$$

其中 $\{x\}$ 表 x 的小数部分, 即 $\{x\} = x - [x], [x]$ 表不超过 x 的最大整数.

8.22 设 $\{\eta_n, n \geq 0\}$ 是平稳序列, $E\eta_n = 0, R(0) = 1, R(r) = \rho, r \neq 0, 0 < \rho < 1$. 证明: η_n 必可表为 $\eta_n = X + \xi_n, n \geq 1$, 其中 X, ξ_1, ξ_2, \dots 不相关, $EX = E\xi_n = 0$, 且 $EX^2 = \rho$ 及 $E\xi_k^2 = 1 - \rho, k \geq 1$.

[提示: 定义 $X \stackrel{m.s.}{=} \lim_{n \rightarrow \infty} (\sum_{k=1}^n \xi_k / n)$.]

8.23 设 $X(t)$ 是雷达发射的信号, 遇到目标后的回波信号是 $aX(t-b)$, $a \ll 1, b$ 是信号往返时间, 而回波必伴有噪声, 记为 $\xi(t)$, 于是接收机收到的信号为 $Y(t) = aX(t-b) + \xi(t)$. 已知 $EX(t) = m_X, R_X(\tau), E\xi(t) = 0, R_\xi(\tau)$. 且 $X(t)$ 和 $\xi(t)$ 平稳相关 $R_{X\xi}(\tau)$. 试求 $X(t), Y(t)$ 的互相关函数 $R_{XY}(\tau)$.

8.24 设 $\xi(t) = X \cos(\eta t + \theta)$, 其中 $\theta \sim U[0, 2\pi], X$ 与 θ 相互独立取值为正, 且 $EX^2 < \infty, \eta > 0$ 为常数. 试证 $\{\xi(t), -\infty < t < +\infty\}$ 为宽平稳过程.

8.25 设 $Z(t) = \sigma \cos(tX + Y)$, 其中 $\sigma > 0$ 为常数, X 取值在 $[0, 1/2]$ 上具有 p.d.f. $f_X(\cdot)$, $Y \sim U[-1/2, 1/2]$ 且与 X 独立.

1) 试证 $\{Z(t), t \geq 0\}$ 是宽平稳过程;

练习题

2) 求它的功率谱密度函数.

8.26 设 $\{X_i(t), -\infty < t < +\infty\}, (1 \leq i \leq 3)$ 为宽平稳过程, 其协方差函数分别为:

1) $R(\tau) = \sigma^2 e^{-\alpha|\tau|}(1 + |\tau|); \quad \alpha > 0, \sigma > 0$

2) $R(\tau) = \sigma^2 e^{-\alpha|\tau|} \cos \beta t; \quad \alpha > 0, \beta > 0 \text{ 为常数}$

3) $R(\tau) = e^{-\alpha|\tau|}(1 + \alpha|\tau| + (\alpha\tau)^2/3); \quad \alpha > 0,$

试分别求其功率谱密度函数.

参考文献

1. S.M.Ross, Stochastic Processes, John Wiley and Sons, 1993.
2. S.Karlin and H.M.Taylor,
A First Course in Stochastic Processes, Academic Press New York seconded, 1975;
A Second Course in Stochastic Processes, Academic Press 1981.
3. J.L.Doob, Stochastic Processes, John Wiley and Sons, 1953.
4. 何声武, 随机过程导论, 高等教育出版社, 1999。
5. 汪荣鑫, 随机过程, 西安交大出版社, 1987。
6. 严颖, 成世学, 程侃, 运筹学随机模型, 中国人民大学出版社, 1995。
7. 邓永录, 梁之舜, 随机点过程及其应用, 科学出版社, 1992。
8. 钱敏平, 龚光鲁, 应用随机过程, 北京大学出版社, 1998。
9. K.L.Chung, Markov chains with stationary Transition Probabilities, 2nd.ed. Springer-Verlag, 1967.
10. N.Ravichandran, Stochastic Methods in Reliability Theory, John Wiley and Sons, 1990.
11. M.H.A.Davis, Markov Models and Optimization, Chapman and Hall, 1993.
12. J.Grandell, Aspects of Risk Theory, Springer-Verlag, 1991.
13. William J.Anderson, Continuous-Time Markov Chains-An Applications-Oriented Approach, Springer-Verlag, 1991.
14. Zdzislaw Brzezniak and Tomasz Zastawniak, Basic stochastic processes : a course through exercises, New York : Springer, 1999 .
15. Peter Todorovic, An Introduction to Stochastic Processes and Their Applications, Springer-Verlag, New York, 1992.
16. Edward.P.C.KAO, An Introduction to Stochastic Processes, Duxbury Press, 1997. by Wadsworth Publishing Company.
17. Bernt Oksendal, Stochastic Differential Equations. An Introduction with Applications. Fourth Edition. Springer-Verlag, 1998.
18. 陆大铨, 随机过程及其应用, 清华大学出版社, 1986.
19. 费勒, 概率论及其应用 (第二卷), 李志阗, 郑之禄译, 科学出版社, 1994.
20. 复旦大学, 随机过程, 人民教育出版社, 1981.
21. 王梓坤, 概率论基础及其应用, 科学出版社, 1976.
22. 林元烈, 随机数学引论, 清华大学讲义, 2001.1.